

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Автоматики і комп'ютеризованих технологій
(повна назва)

Кафедра Комп'ютерно-інтегрованих технологій, автоматизації та робототехніки
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА

Пояснювальна записка

рівень вищої освіти другий (магістерський)

Розроблення асоціативних правил для автоматизованої системи

прогнозування поломок на автомобільному виробництві

(тема)

Виконав:

здобувач II-го року навчання,

групи КІТІВМ-23-1

Іщенко М.Д.

(прізвище, ініціали)

Спеціальність 174 Автоматизація та

комп'ютерно-інтегровані технології

(код і повна назва спеціальності)

Тип програми освітньо-професійна

(освітньо-професійна або освітньо-наукова)

Освітня програма Комп'ютерно-інтегровані

технологічні процеси і виробництва

(повна назва освітньої програми)

Керівник доц. Максимова С.С.

(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри

(підпис)

Невлюдов І.Ш.

(прізвище, ініціали)

2025 р.

Харківський національний університет радіоелектроніки

Факультет _____ АКТ _____

Кафедра _____ КІТАР _____

Рівень вищої освіти _____ Другий (магістерський) _____

Спеціальність 174 Автоматизація та комп'ютерно-інтегровані технології
(код і повна назва)

Тип програми _____ Освітньо-професійна _____
(освітньо-професійна або освітньо-наукова)

Освітня програма Комп'ютерно-інтегровані технологічні процеси і виробництва
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

« _____ » _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Іщенко Михайлу Дмитровичу _____
(прізвище, ім'я, по батькові)

- Тема роботи _____ Розроблення асоціативних правил для автоматизованої системи прогнозування поломок на автомобільному виробництві _____
затверджена наказом університету від 22 листопада 2024 р. № 1231Ст
- Термін подання здобувачем роботи до екзаменаційної комісії 31 січня 2025 р.
- Вихідні дані до роботи Розробити асоціативні правила для автоматизованої системи прогнозування поломок на автомобільному виробництві, користуючись Windows 11, мовою програмування Python та середовищем розробки PyCharm
- 4.1 Вступ 4.2 Методологія прогнозування поломок на автомобільному виробництві на основі асоціативних правил 4.2 Розроблення системи прогнозування поломок 4.3 Розроблення програмного застосування для прогнозування поломок 4.4 Експериментальне дослідження та аналіз результатів 4.5 Експериментальне дослідження та аналіз результатів 4.6 Впровадження інноваційної системи на автомобільному виробництві 4.7 Безпека праці та екологічні аспекти 4.8 Висновки 4.9 Перелік джерел посилання.

Я як студент ХНУРЕ розумію і підтримую політику закладу із академічної доброчесності. Я не надавав і не одержував недозволену допомогу під час підготовки кваліфікаційної роботи. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело.

20 січня 2025 р.



Ищенко М.Д.

РЕФЕРАТ

Пояснювальна записка: 73 с., 17 рис., 8 форм., 4 дод., 55 джерел.

АСОЦІАТИВНІ ПРАВИЛА, APRIORI, DBSCAN, ПРОГНОЗНА АНАЛІТИКА, АВТОМАТИЗАЦІЯ, ВИРОБНИЦТВО

Об'єктом дослідження є процес генерації асоціативних правил.

Предметом дослідження є система прогнозування поломок на автоматизованому виробництві.

Метою дослідження є підвищення ефективності та безпечності роботи підприємства за рахунок розробки моделі для прогнозування поломок на основі асоціативних правил.

Завданням дослідження є генерація асоціативних правил з метою прогнозування часу появи аномальних значень та їх наслідків. Отримана методика перевірена на синтетично згенерованих даних, які б відповідали реальним показникам сенсорів на автомобільному виробництві.

Результатом дослідження є алгоритм генерації асоціативних правил на основі кластеризованих значень часових рядів. Логіка алгоритму підтримує можливості масштабування кількості станків для аналізу та їх сенсорів, що дозволяє імплементувати її у підприємство будь якого розміру.

Робота має практичне значення для підприємств будь якої сфери за рахунок зменшення фінансових витрат на усунення поломок та зупинок виробництва. Також алгоритм додає безпечності виробництву, дозволяючи з певною ймовірністю прогнозувати поломки, дозволяючи наявному персоналу виконувати інструкції ще до появи самої поломки. Результати роботи алгоритму практично розглянуті на прикладі автомобільного підприємства.

Рекомендацією до імплементації цього алгоритму є будь яке виробництво зацікавлене у фінансовій та/або безпековій складовій.

Результати кваліфікаційної роботи апробовані у всеукраїнській студентській конференції та у збірнику наукових робіт категорії «Б» Переліку наукових фахових видань України.

Отримані результати можна віднести до Цілей сталого розвитку 8 «Гідна праця та економічне зростання», а саме до пунктів 8.2 «Підвищувати ефективність виробництва на засадах сталого розвитку та розвитку високотехнологічних конкурентних виробництв» та 8.5 «Сприяти забезпеченню надійних та безпечних умов праці для всіх працюючих, зокрема шляхом застосування інноваційних технологій у сфері охорони праці та промислової безпеки».

ABSTRACT

Explanatory Note: 73 pages, 17 figures, 8 formulas, 4 applications, 55 sources

ASSOCIATIVE RULES, APRIORI, DBSCAN, PREDICTIVE ANALYTICS,
AUTOMATION, PRODUCTION

The object of research is the process of generating associative rules.

The subject of the study is a system for predicting breakdowns in automated production.

The aim of the study is to increase the efficiency and safety of the enterprise by developing a model for predicting breakdowns based on associative rules.

The task of the study is to generate associative rules to predict the time of occurrence of abnormal values and their consequences. The obtained methodology is tested on synthetically generated data that would correspond to the real indicators of sensors in automotive production.

The result of the study is an algorithm for generating associative rules based on clustered time series values. The algorithm's logic supports the ability to scale the number of machines to be analyzed and their sensors, which allows it to be implemented in an enterprise of any size.

The work is of practical importance for enterprises of any industry by reducing the financial costs of eliminating breakdowns and production stoppages. The algorithm also adds safety to production by allowing breakdowns to be predicted with a certain probability, allowing available personnel to follow instructions before the breakdown itself occurs. The results of the algorithm are practically examined on the example of an automotive company.

The recommendation for implementing this algorithm is for any production facility interested in the financial and/or security component.

The results of the qualification work were tested at the All-Ukrainian Student Conference and in the collection of scientific papers of category «B» of the List of Scientific Professional Publications of Ukraine.

The results obtained can be attributed to Sustainable Development Goal 8 «Decent Work and Economic Growth», namely to paragraphs 8.2 «Increase production efficiency on the basis of sustainable development and development of high-tech competitive industries» and 8.5 «Promote safe and secure working conditions for all workers, in particular through the use of innovative technologies in the field of labor protection and industrial safety».

ЗМІСТ

| | |
|---|----|
| Перелік умовних позначень та скорочень..... | 11 |
| Вступ | 12 |
| 1 Методологія прогнозування поломок на автомобільному виробництві на основі асоціативних правил | 14 |
| 1.1 Аналіз предметної області..... | 14 |
| 1.2 Основи прогнозовної аналітики | 16 |
| 1.3 Алгоритми асоціативного аналізу | 18 |
| 1.4 Використання DBSCAN для виявлення аномалій..... | 22 |
| 1.5 Інтеграція Apriori для прогнозування подій..... | 24 |
| 1.6 Висновки до першого розділу..... | 26 |
| 2 Розроблення системи прогнозування поломок..... | 28 |
| 2.1 Архітектура рішення..... | 28 |
| 2.2 Алгоритми обробки даних із сенсорів | 29 |
| 2.3 Застосування часових вікон для ідентифікації закономірностей ... | 31 |
| 2.4 Обґрунтування вибору алгоритмів машинного навчання | 33 |
| 2.5 Використання теорії автоматичного управління в прогнозуванні | 34 |
| поломок | |
| 2.6 Висновки до другого розділу | 35 |
| 3 Розроблення програмного застосунку для прогнозування поломок | 37 |
| 3.1 Вимоги до програмного забезпечення | 37 |
| 3.2 Інтерфейс користувача для введення параметрів аналізу..... | 38 |
| 3.3 Реалізація інтеграції алгоритмів DBSCAN та Apriori. | 40 |
| 3.4 Візуалізація результатів..... | 44 |
| 3.5 Висновки до третього розділу | 48 |
| 4 Експериментальне дослідження та аналіз результатів | 50 |
| 4.1 Практичний експеримент | 50 |
| 4.2 Висновки до четвертого розділу..... | 53 |

| | |
|--|----|
| 5 Впровадження інноваційної системи на автомобільному виробництві | 55 |
| 5.1 Особливості інтеграції у виробничі процеси | 55 |
| 5.2 Потенційні труднощі та шляхи їх подолання | 56 |
| 5.3 Економічний ефект від впровадження системи..... | 58 |
| 5.4 Висновки до п'ятого розділу..... | 59 |
| 6 Безпека праці та екологічні аспекти | 60 |
| 6.1 Аналіз потенційних ризиків при використанні системи..... | 60 |
| 6.2 Організація безпечної експлуатації обладнання та ПЗ | 61 |
| 6.3 Екологічні переваги та зменшення енергоспоживання | 62 |
| 6.4 Висновки до шостого розділу | 64 |
| Висновки..... | 66 |
| Перелік джерел посилання..... | 68 |
| Додаток А Посібник користувача | 74 |
| Додаток Б Апробація результатів кваліфікаційної роботи..... | 82 |
| Додаток В Висвітлення результатів кваліфікаційної роботи..... | 92 |
| Додаток Г Текст програми | 99 |

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ ТА СКОРОЧЕНЬ

ПЗ (Програмне забезпечення) – сукупність програм, даних та інструкцій, які використовуються для виконання задач на обчислювальних пристроях;

ХНУРЕ (Харківський Національний Університет Радіоелектроніки) – вищий навчальний заклад у галузі радіоелектроніки та інформаційних технологій;

DBSCAN (Density-Based Spatial Clustering of Applications with Noise) – алгоритм кластеризації, який дозволяє виділяти групи точок у багатовимірному просторі на основі їхньої щільності, а також ідентифікувати аномалії як точки, що не належать до жодного кластера;

DevOps (Development and Operations) – підхід до розробки програмного забезпечення, що об'єднує процеси розробки та експлуатації для забезпечення швидкої доставки, надійності та якості ІТ-продуктів;

ІТ (Information Technology) – інформаційні технології, сукупність методів, засобів і процесів для створення, обробки, зберігання, передачі та використання інформації в електронному вигляді;

ML (Machine Learning) – машинне навчання, підгалузь штучного інтелекту, яка зосереджується на розробці алгоритмів і моделей, що дозволяють комп'ютерним системам навчатися та робити прогнози на основі даних.

ВСТУП

У сучасному виробництві, зокрема в автомобільній галузі, значна роль відводиться ефективному управлінню ресурсами та мінімізації ризиків, що виникають через поломки обладнання. Одним із найбільших викликів є прогнозування можливих відмов у роботі техніки, що дозволяє запобігти аваріям, оптимізувати процеси технічного обслуговування і знизити економічні витрати, пов'язані з простоем виробництва. Прогнозування таких подій, зокрема поломок, ускладнюється через велику кількість змінних, що впливають на виробничі процеси, а також необхідність обробки значних обсягів даних, які надходять із сенсорних систем і моніторингових платформ.

Один із ефективних підходів до вирішення цієї проблеми – це використання алгоритмів пошуку асоціативних правил, зокрема алгоритму «Аргіогі». Асоціативні правила дають змогу виявляти приховані залежності між різними параметрами виробничого процесу, такими як температура, тиск, час роботи, вологість тощо, що можуть взаємно впливати на стан обладнання. За допомогою таких правил можна передбачати не лише ймовірність поломки, а й вплив певних змінних на її виникнення, що дозволяє більш точно моделювати процеси й створювати ефективні стратегії для зниження ймовірності аварій.

Прогнозна аналітика, яка використовує методи пошуку асоціативних правил є важливим інструментом для автоматизованого моніторингу і прогнозування стану виробничих систем. Завдяки цим методам можна виявляти приховані закономірності в великих обсягах даних, що генеруються сенсорними системами, і на основі цих даних створювати моделі, що точно передбачають ймовірність виникнення поломок. Водночас, асоціативні правила дозволяють виявити не лише найбільш очевидні взаємозв'язки, але й менш помітні фактори, які можуть мати значний вплив на стан техніки.

Метою дослідження є підвищення ефективності та безпечності роботи підприємства за рахунок розробки моделі для прогнозування поломок на основі асоціативних правил, що дозволить знизити витрати на технічне обслуговування, забезпечити надійність і безпеку виробничих процесів, а також оптимізувати роботу обладнання на всіх етапах виробництва. Для досягнення цієї мети будуть використані алгоритми пошуку асоціативних правил, зокрема «Аргіорі», які дозволяють знаходити неочевидні залежності між різними параметрами, що впливають на поломки. В результаті буде розроблено ефективне рішення для автоматизованого прогнозування поломок та зниження ризиків, пов'язаних з відмовами техніки на виробництві.

Пояснювальна записка з кваліфікаційної роботи виконано згідно матеріалів [1-4].

1 МЕТОДОЛОГІЯ ПРОГНОЗУВАННЯ ПОЛОМОК НА АВТОМОБІЛЬНОМУ ВИРОБНИЦТВІ НА ОСНОВІ АСОЦІАТИВНИХ ПРАВИЛ

1.1 Аналіз предметної області

Автомобільна промисловість є однією з найбільш технологічно складних і високоточних сфер діяльності, де кожен етап виробництва вимагає строгого контролю за станом обладнання, що використовується. У цьому контексті прогнозування поломок на автомобільному виробництві стає надзвичайно важливим інструментом для зниження витрат і підвищення ефективності процесів. Забезпечення безперервної роботи обладнання, своєчасне виявлення потенційних проблем і недопущення аварійних ситуацій – це ключові завдання для будь-якого виробничого підприємства. Враховуючи інтенсивність і складність виробничих процесів, прогнозування поломок стає необхідним для оптимізації та забезпечення стабільності роботи виробництва.

У сучасному автомобільному виробництві проблеми, пов'язані з поломками, виникають через безліч факторів, таких як знос обладнання, помилки в експлуатації, невірно налаштовані параметри машин і технологічні порушення. Технологічний процес виробництва автомобілів передбачає використання великої кількості різноманітних механізмів, що працюють у постійному режимі. Всі ці пристрої піддаються різноманітним навантаженням, що неминуче призводить до їхнього зношування або несправності. У такій ситуації вкрай важливо мати систему, яка дозволяє не лише виявляти факти поломок, а й прогнозувати їх заздалегідь, що дозволяє підприємствам оптимізувати процеси технічного обслуговування та мінімізувати час простою обладнання.

Методи прогнозування поломок на автомобільних виробництвах здебільшого ґрунтуються на аналізі великих обсягів даних, отриманих від різноманітних сенсорів і моніторингових систем [5]. Завдяки постійному вдосконаленню технологій збору даних, а також розвитку математичних і

статистичних методів обробки цих даних, стало можливим здійснення прогнозів щодо часу до поломки обладнання або виявлення дефектів на ранніх етапах їхнього розвитку. Одним із найбільш ефективних інструментів для досягнення цієї мети є асоціативні правила, які дозволяють виявляти приховані зв'язки і закономірності між різними параметрами виробничого процесу та можливими поломками.

Асоціативні правила є методами, що належать до групи статистичних методів, здатних виявляти залежності між елементами даних, що зустрічаються в певних умовах. Вони дозволяють знаходити зв'язки між різними подіями або ознаками, які можуть впливати на ймовірність виникнення певної події, наприклад, поломки. Застосування асоціативних правил у прогнозуванні поломок на автомобільному виробництві дозволяє здійснити глибокий аналіз взаємозв'язків між факторами, що можуть спричиняти дефекти в роботі машин. Це дозволяє зменшити кількість неочікуваних поломок і забезпечити своєчасне втручання в разі виявлення небезпечних тенденцій.

Предметною областю для використання асоціативних правил є комплексні системи, де взаємодіють різноманітні компоненти – від механічних частин до електронних систем управління. Вибір найбільш ефективних методів прогнозування поломок, таких як асоціативні правила, значно залежить від типу та структури даних, які зібрані в рамках виробничого процесу. Застосування асоціативних правил передбачає наявність великих баз даних, що включають історію роботи обладнання, час поломок, параметри експлуатації.

Одним із важливих аспектів аналізу предметної області є вибір правильних змінних, що впливають на ймовірність поломки, а також розуміння того, як різні чинники взаємодіють між собою. Наприклад, не тільки самі поломки важливі, але й супутні фактори, такі як температура, навантаження, швидкість обертання, час роботи без перерви тощо. Виявлення закономірностей між цими факторами допомагає створити модель прогнозування, яка може передбачити можливі проблеми задовго до їхнього фактичного виникнення.

Таким чином, застосування асоціативних правил для прогнозування поломок на автомобільному виробництві є важливим етапом у розвитку інтелектуальних

систем для управління виробничими процесами. Визначення та аналіз факторів, що впливають на виникнення поломок, є основою для створення надійної прогностичної моделі, здатної мінімізувати ризики та забезпечити безперебійність роботи виробничих потужностей.

1.2 Основи прогнозової аналітики

У процесі розробки систем прогнозування поломок на автомобільному виробництві важливо враховувати значення прогнозової аналітики як складової частини інтелектуальних систем підтримки прийняття рішень. Прогнозна аналітика є важливою галуззю аналізу даних, що базується на статистичних, математичних і алгоритмічних методах, які дають можливість здійснювати точне передбачення про майбутні події, поведінку об'єктів або тенденції на основі аналізу наявних даних. Прогнозування застосовується в різних сферах, але особливо важливим є його використання для підвищення ефективності та безпеки виробничих процесів на автомобільних виробництвах. Прогнозна аналітика має кілька напрямків, зокрема, побудову моделей для передбачення поломок на основі взаємозв'язків між різними факторами, що впливають на роботу обладнання.

У рамках прогнозової аналітики для виявлення потенційних поломок застосовуються різні підходи, серед яких найбільше зустрічаються методи регресії, часових рядів та класифікації [6]. Використовуючи такі техніки, можна побудувати моделі, які враховують складні взаємозв'язки між різними змінними, що виникають під час виробничого процесу. Одним із важливих напрямків, який активно застосовується в прогнозуванні, є пошук асоціативних правил, що допомагає виявити приховані закономірності в даних і на основі цього будувати точніші прогнози.

Особливістю прогнозової аналітики є те, що вона дозволяє не лише здійснити прогноз на майбутнє, а й визначити ймовірні наслідки подій, таких як продовження аномалій чи навіть поломок, що дає змогу більш точно оцінити потенційні витрати та втрати від непередбачених ситуацій. Це дозволяє підприємствам не лише

знижувати ймовірність аварій, але й оптимізувати витрати на технічне обслуговування та ремонти. Інструменти прогнозної аналітики дозволяють своєчасно виявляти потенційні проблеми, що можуть призвести до поломок, і вжити заходів для їхнього попередження.

Прогнозна аналітика також включає в себе підготовку даних, що є важливою частиною процесу побудови ефективних прогнозів. Дані, які надходять із сенсорів і моніторингових систем, можуть бути неповними або містити шуми, що вимагає їхньої попередньої обробки. Це включає очищення даних, нормалізацію та імпутацію пропущених значень, щоб забезпечити високу якість та точність подальших аналізів. Прогнозна аналітика дозволяє використовувати як історичні дані, так і поточні показники для створення моделей, здатних на основі отриманої інформації робити передбачення щодо майбутніх подій. Важливим етапом цього процесу є визначення найбільш підходящих моделей для конкретного випадку, наприклад, для прогнозування поломок на автомобільному виробництві це можуть бути моделі, які здатні враховувати вплив різних змінних, таких як температура, час роботи обладнання, навантаження та інші параметри.

Методи прогнозної аналітики також дозволяють створювати інтелектуальні системи підтримки прийняття рішень, які здатні автоматично генерувати прогнози на основі зібраних даних. Такі системи дозволяють здійснювати аналіз великих обсягів інформації в реальному часі, що є важливим для оперативного реагування на зміни в умовах виробничого процесу. Завдяки таким системам, можна не лише вчасно виявляти поломки, але й зменшувати ризики, пов'язані з простоєм обладнання, оптимізувати роботу виробничих ліній та знижувати витрати на обслуговування.

Прогнозна аналітика є потужним інструментом для підвищення надійності та безпеки виробничих процесів на автомобільному виробництві. Застосування асоціативних правил у прогнозних моделях дає можливість враховувати множинні фактори, що впливають на можливість виникнення несправностей, і таким чином підвищує точність прогнозів. Це дозволяє зменшити ймовірність аварій, знизити витрати та покращити ефективність виробництва, що робить застосування

прогнозна аналітика надзвичайно важливим для будь-якого сучасного виробничого підприємства.

1.3 Алгоритми асоціативного аналізу

Асоціативний аналіз є фундаментальним інструментом у галузі аналізу даних для виявлення закономірностей у великих наборах даних. Його основна мета полягає у виявленні прихованих залежностей між об'єктами, які можуть залишатися непоміченими при використанні стандартних методів аналізу [7-8]. Застосування асоціативного аналізу особливо актуальне для автоматизованих систем, що обробляють великі обсяги інформації, таких як системи моніторингу та прогнозування поломок на виробництві. Виявлені залежності не тільки описують характерні взаємозв'язки між параметрами, але й слугують основою для створення прогнозних моделей, здатних з високою точністю передбачати виникнення несправностей.

Одним із найпоширеніших інструментів для виконання асоціативного аналізу є алгоритм Apriori. Цей алгоритм має ітеративну структуру, яка дозволяє поступово відсіювати набори елементів, що не відповідають заданим критеріям, такими як мінімальна підтримка чи впевненість тощо. Алгоритм використовує принцип «анти-монотонності», завдяки якому час виконання значно скорочується, оскільки неперспективні набори виключаються на ранніх етапах. Приклад «антимонотонності» зображено на рис. 1.1.

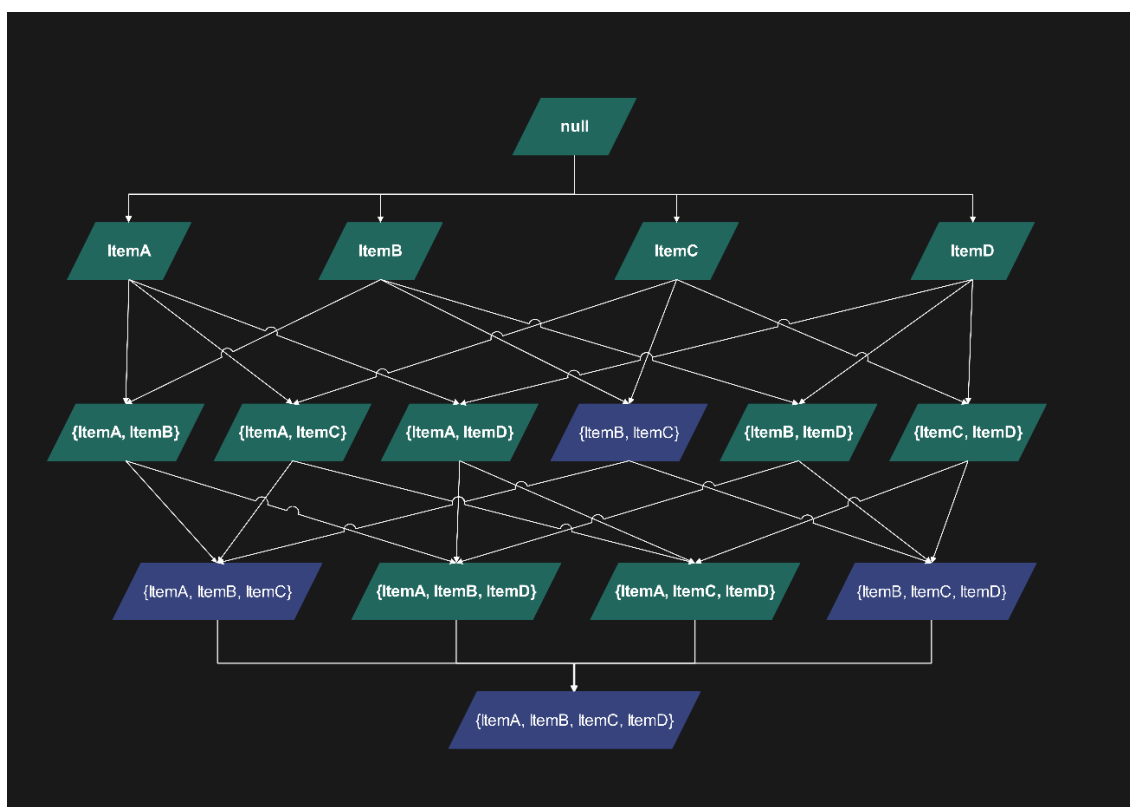


Рисунок 1.1 – Візуалізація антимонотонної властивості алгоритму «Apriori»

Унікальність Apriori полягає у здатності обробляти величезні масиви даних, що робить його незамінним у задачах, де потрібно враховувати великий обсяг взаємодій між параметрами.

Для оцінки знайдених залежностей алгоритм Apriori використовує низку метрик, кожна з яких має своє математичне підґрунтя та специфічне значення у контексті аналізу даних. Ці метрики допомагають визначити, наскільки часто виникає певний набір елементів, наскільки вони взаємопов'язані та чи є ці зв'язки статистично значущими. Описані нижче параметри формують основу для оцінки асоціативних правил.

Підтримка є однією з базових метрик асоціативного аналізу, яка використовується для оцінки частоти появи певного набору елементів у загальному наборі транзакцій. Вона визначає популярність набору і допомагає відсіяти малозначущі комбінації. Підтримку можна обчислити за допомогою формули (1.1):

$$\text{Support}(A) = \frac{|T(A)|}{|T|} \quad (1.1)$$

де $|T(A)|$ – кількість транзакцій, що містять набір A ,
 $|T|$ – загальна кількість транзакцій у наборі даних.

Високе значення підтримки свідчить про те, що набір елементів часто зустрічається, однак саме по собі не гарантує, що цей набір має прогностичну цінність.

Якщо підтримка визначає, наскільки часто певний набір з'являється у наборі даних, то впевненість дає змогу оцінити силу зв'язку між двома наборами елементів. Вона показує ймовірність того, що один набір (наприклад, B) буде присутній у транзакції за умови наявності іншого набору (A). Для обчислення впевненості існує формула (1.2):

$$\text{Confidence}(A \rightarrow B) = \frac{\text{Support}(A \cup B)}{\text{Support}(A)} \quad (1.2)$$

Ця метрика важлива для оцінки передбачуваності правил. Наприклад, якщо впевненість для правила $A \rightarrow B$ становить 0.9, це означає, що в 90% випадків, коли з'являється A , також присутній B .

Впевненість є корисною метрикою, однак вона не враховує загальну частоту появи B . Приріст вирішує цю проблему, порівнюючи впевненість правила з випадковою ймовірністю появи B . Формула (1.3) для обчислення приросту виглядає наступним чином:

$$\text{Lift}(A \rightarrow B) = \frac{\text{Confidence}(A \rightarrow B)}{\text{Support}(B)} \quad (1.3)$$

$\text{Lift} > 1$ свідчить про позитивну кореляцію між A і B , що вказує на сильний зв'язок між ними. $\text{Lift} = 1$ означає, що між A і B немає зв'язку, тоді як $\text{Lift} < 1$ вказує на негативну кореляцію.

Важільність є показником, що оцінює різницю між фактичною частотою появи $A \cup B$ та очікуваною частотою, якщо ці набори були б незалежними. Формула (1.4) для розрахунку значення важільності виглядає так:

$$\text{Leverage}(A \rightarrow B) = \text{Support}(A \cup B) - \text{Support}(A) * \text{Support}(B) \quad (1.4)$$

Leverage дає змогу оцінити силу залежності між A і B , враховуючи їхню очікувану частоту.

Переконаність дозволяє оцінити силу зв'язку між наборами з урахуванням їхньої взаємної залежності. Вона визначається за допомогою формули (1.5):

$$\text{Conviction}(A \rightarrow B) = \frac{1 - \text{Support}(B)}{1 - \text{Confidence}(A \rightarrow B)} \quad (1.5)$$

Високе значення переконаності свідчить про те, що правило є значущим та не є випадковим.

Коефіцієнт Жаккарда вимірює ступінь подібності між наборами A та B , розраховуючи співвідношення перетину до об'єднання за допомогою формули (1.6):

$$\text{Jaccard}(A, B) = \frac{\text{Support}(A \cap B)}{\text{Support}(A) + \text{Support}(B) - \text{Support}(A \cap B)} \quad (1.6)$$

Ця метрика корисна для оцінки схожості між елементами в наборі даних.

Визначеність показує силу асоціації між елементами, зокрема наскільки частота спільної появи A і B перевищує їхню незалежну появу за допомогою формули (1.7):

$$\text{Certainty}(A \rightarrow B) = \frac{\text{Support}(A \cap B) - \text{Support}(A) * \text{Support}(B)}{\text{Support}(A)} \quad (1.7)$$

Індекс Кульчинського (Kulczynski Index) оцінює симетрію залежності між наборами A і B за допомогою формули (1.8):

$$Kulczynski(A, B) = \frac{1}{2} \left(\frac{Support(A \cup B)}{Support(A)} + \frac{Support(A \cup B)}{Support(B)} \right) \quad (1.8)$$

Використання цих метрик дозволяє глибоко аналізувати існуючі залежності між параметрами, формуючи ефективні асоціативні правила для задач прогнозування. Плавний перехід між метриками, а також їхнє взаємне доповнення забезпечують комплексний підхід до оцінки закономірностей у великих наборах даних.

1.4 Використання DBSCAN для виявлення аномалій

DBSCAN (Density – Based Spatial Clustering of Applications with Noise) є одним із найбільш поширених алгоритмів кластеризації, який базується на аналізі щільності даних. Його головною перевагою є здатність виявляти аномальні точки, які не належать жодному кластеру, а також ефективність роботи з нерівномірно розподіленими даними [9-11]. У контексті прогнозування поломок на автомобільному виробництві DBSCAN може бути використаний для аналізу часових рядів параметрів, таких як температура, швидкість, струм та інші показники, для ідентифікації незвичайних станів системи.

Принцип роботи алгоритму DBSCAN базується на визначенні щільних областей у багатовимірному просторі даних. Він використовує два основні параметри: радіус щільності (eps) та мінімальну кількість точок (min_samples). Точки, які мають достатньо сусідів у межах радіусу eps, вважаються «ядром» кластера, тоді як інші точки можуть бути приєднані до кластера або ідентифіковані як «шум» або ж «аномалії» в нашому випадку, якщо вони не відповідають заданим критеріям. Цей підхід дозволяє DBSCAN адаптуватися до складних форм кластерів

і працювати без необхідності задавати кількість кластерів заздалегідь, що є важливим для аналізу реальних виробничих даних.

У задачах прогнозування поломок DBSCAN ефективно працює з часовими рядами, які відображають зміну параметрів роботи обладнання у часі. Наприклад, раптове зниження тиску в гідравлічній системі або стрибок температури двигуна можуть бути ідентифіковані як аномалії. Для цього спочатку часовий ряд перетворюється у багатовимірний простір, де кожен вимір відповідає окремому параметру або часовому маркеру. Далі алгоритм кластеризує точки, виділяючи ті, що значно відрізняються від загальної поведінки. Ці аномалії можуть бути ранніми індикаторами майбутніх поломок, що дозволяє вчасно вжити заходів для їхнього запобігання.

Важливою особливістю DBSCAN є його здатність працювати з шумовими даними, які часто присутні у виробничих процесах. Завдяки цьому алгоритм може ефективно фільтрувати незначні коливання, які не є критичними для роботи системи, і концентрувати увагу на дійсно важливих аномаліях. Це забезпечує високу точність прогнозів і зменшує кількість хибнопозитивних спрацьовувань, але в нашому випадку шум, це фактично і є аномалії, які відбилися від основних груп показників.

Налаштування параметрів ϵ та min_samples є важливим етапом у роботі з DBSCAN, оскільки вони значно впливають на результати кластеризації. Наприклад, завищене значення ϵ може призвести до утворення надмірно великих кластерів, які включатимуть аномалії, тоді як занадто низьке значення ϵ може зробити кластеризацію занадто жорсткою, що призведе до значного збільшення кількості точок, класифікованих як шум. Аналогічно, параметр min_samples визначає мінімальну кількість точок, необхідну для формування кластеру, і його вибір має базуватися на характеристиках аналізованих даних, таких як частота запису даних та обсяги виробництва.

Практичне використання DBSCAN у системах прогнозування поломок включає інтеграцію алгоритму в програмне забезпечення, яке обробляє дані з сенсорів. Це дозволяє виявляти аномальні події ще до того, як вони вплинуть на

роботу виробничого обладнання. Наприклад, при моніторингу роботи двигуна алгоритм може виявити комбінацію високої температури та збільшення струму, яка часто передує перегріву. Своєчасне виявлення таких станів дозволяє запобігти серйозним наслідкам, таким як зупинка виробничої лінії.

Приклад кластеризації за допомогою алгоритму кластеризації на основі щільності DBSCAN наведено на рис. 1.2.



Рисунок 1.2 – Приклад кластеризації за допомогою алгоритму DBSCAN

Таким чином, DBSCAN є потужним інструментом для виявлення аномалій у великих і складних наборах даних. Його здатність працювати з шумовими даними, визначати аномалії та адаптуватися до нерівномірного розподілу точок робить його незамінним для прогнозування поломок на автомобільному виробництві. Інтеграція DBSCAN у систему моніторингу дозволяє значно підвищити її ефективність, зменшити кількість несподіваних зупинок та забезпечити безпеку роботи обладнання.

1.5 Інтеграція Apriori для прогнозування подій

Інтеграція алгоритму Apriori у систему прогнозування подій є ключовим етапом у розробці автоматизованих рішень для моніторингу та управління виробничими процесами. Алгоритм Apriori, завдяки своїй здатності виявляти часті набори елементів у великих наборах даних, забезпечує створення асоціативних правил, які описують причинно-наслідкові зв'язки між параметрами системи. У контексті автомобільного виробництва це дозволяє прогнозувати виникнення поломок на основі аналізу історичних даних про роботу обладнання.

Процес інтеграції алгоритму Apriori у систему прогнозування включає кілька етапів. На першому етапі відбувається підготовка даних, що передбачає збір та попередню обробку інформації, отриманої із сенсорів виробничого обладнання. Ці дані формуються у вигляді транзакцій, де кожен запис містить інформацію про стан обладнання у певний момент часу. Наприклад, одна транзакція може включати такі параметри, як температура двигуна, струм, навантаження та швидкість.

Наступним етапом є використання алгоритму DBSCAN для кластеризації даних і виявлення аномалій, які стають основою для подальшого аналізу. Виділені аномальні точки позначаються як події, що потребують підвищеної уваги, і формують базу для створення асоціативних правил за допомогою алгоритму Apriori. На цьому етапі визначаються два кластери, нормальної роботи та аномалій.

Наприклад, підвищення температури двигуна та зменшення швидкості обертання валу можуть вказувати на ймовірність перегріву, що за собою несе аномальний стан.

Інтеграція алгоритму Apriori забезпечує можливість автоматичного створення правил, які прогнозують події, використовуючи історичні дані [12-13]. Наприклад, одне з правил може виглядати так: «Якщо струм двигуна перевищує 50А, а температура зростає вище 90°C, то з ймовірністю 85% виникає перегрів». Такі правила дозволяють системі моніторингу не лише реагувати на поточний стан обладнання, але й здійснювати прогностичний аналіз, попереджаючи персонал про потенційні несправності.

Практичне застосування інтеграції Apriori охоплює розробку програмного забезпечення, яке дозволяє у реальному часі аналізувати дані та генерувати асоціативні правила. Це програмне забезпечення може бути інтегроване з існуючими системами моніторингу та управління, що дозволяє оптимізувати процеси технічного обслуговування. Наприклад, у разі виявлення правил, які вказують на підвищений ризик поломки, система може автоматично генерувати сповіщення або навіть запускати процедури аварійного відключення.

Ключовою перевагою інтеграції Apriori є її масштабованість і гнучкість. Алгоритм може бути адаптований для роботи з будь-яким типом обладнання,

незалежно від кількості сенсорів чи параметрів, що аналізуються. Це дозволяє використовувати його у великих промислових підприємствах, забезпечуючи високу ефективність і надійність роботи виробничих ліній.

Таким чином, інтеграція алгоритму Apriori у систему прогнозування подій відкриває нові можливості для аналізу та управління виробничими процесами. Це робить алгоритм Apriori важливим елементом сучасних систем прогнозування у межах концепції Industry 4.0.

1.6 Висновки до першого розділу

У першому розділі розглянуто методологію прогнозування поломок на автомобільному виробництві на основі асоціативних правил. Було проведено детальний аналіз предметної області, що дозволило визначити ключові проблеми сучасного виробництва, пов'язані з забезпеченням безперебійної роботи обладнання та мінімізацією простоїв. Розглянуто основи прогнозної аналітики, яка є ефективним інструментом для аналізу великих обсягів даних, отриманих із сенсорів, та передбачення потенційних несправностей.

Особливу увагу приділено алгоритмам асоціативного аналізу, зокрема Apriori, який дозволяє визначати часті закономірності між параметрами обладнання та формувати асоціативні правила.

Також досліджено можливості алгоритму DBSCAN для кластеризації даних і виявлення аномалій у часових рядах, які відображають зміну параметрів роботи обладнання. Використання цього алгоритму дозволяє виділяти аномальні стани системи, які є попередниками потенційних несправностей. Його здатність працювати з нерівномірно розподіленими даними та ідентифікувати шум робить DBSCAN незамінним для аналізу складних виробничих процесів.

Інтеграція алгоритмів DBSCAN та Apriori у єдину систему дозволяє реалізувати повноцінний підхід до прогнозування несправностей [14]. DBSCAN виконує функцію попередньої обробки даних і виявлення аномалій, тоді як Apriori забезпечує генерацію правил для прогнозування. Така інтеграція забезпечує високу

точність прогнозів та ефективність роботи системи моніторингу, що сприяє оптимізації виробничих процесів.

Таким чином, результати аналізу методології підтверджують доцільність використання поєднання кластеризаційних методів і асоціативного аналізу для автоматизованих систем прогнозування. Вони створюють основу для подальшої розробки і впровадження програмного забезпечення, яке забезпечить раннє виявлення несправностей, мінімізує фінансові втрати та підвищить безпеку праці на виробництві.

2 РОЗРОБЛЕННЯ СИСТЕМИ ПРОГНОЗУВАННЯ ПОЛОМОК

2.1 Архітектура рішення

Архітектура рішення для автоматизованої системи прогнозування поломок ґрунтується на сучасних підходах до обробки великих обсягів даних. Основною метою цієї системи є забезпечення ефективного збору, обробки та аналізу даних, отриманих із сенсорів виробничого обладнання, для виявлення потенційних несправностей [15]. Такий підхід дозволяє не лише вчасно виявляти проблеми, але й запобігати можливим аваріям, що позитивно впливає на безпеку праці та економічну ефективність виробництва.

Дані, що надходять до системи, попередньо обробляються для підвищення їхньої якості. Цей процес включає імпутацію пропущених значень, нормалізацію та агрегацію у часові вікна. Наприклад, значення температури чи струму, зібрані у різний час, агрегуються у вигляді середніх або максимальних значень за визначений проміжок часу. Така обробка дозволяє отримати дані у структурованому вигляді, готові до подальшого аналізу. Особливу увагу приділяють обробці аномальних значень, які можуть бути маркерами майбутніх несправностей.

На наступному етапі дані обробляються аналітичним модулем системи. Його робота базується на використанні двох основних алгоритмів: DBSCAN та Apriori. Алгоритм DBSCAN виконує кластеризацію даних та ідентифікацію аномалій у часових рядах, що дозволяє виділити потенційно небезпечні стани обладнання. Ці аномалії слугують вхідними даними для алгоритму Apriori, який створює асоціативні правила. Виявлені правила описують залежності між параметрами, що передують виникненню несправностей.

Результати аналізу візуалізуються за допомогою інтерактивного інтерфейсу, який надає доступ до графіків, що відображають динаміку ключових параметрів,

виявлені аномалії та асоціативні правила. Інтерфейс дозволяє оператору легко ідентифікувати потенційні проблеми та своєчасно реагувати на них.

Архітектура рішення забезпечує інтеграцію всіх компонентів у єдину систему через централізовану шину даних. Це дозволяє забезпечити ефективну взаємодію між рівнями збору, обробки та аналізу даних, а також візуалізації результатів. Така модульна структура забезпечує гнучкість і масштабованість системи, дозволяючи адаптувати її до потреб різних виробничих підприємств. У підсумку, архітектура автоматизованої системи прогнозування поломок створює основу для підвищення ефективності, надійності та безпеки виробничих процесів.

2.2 Алгоритми обробки даних із сенсорів

Обробка даних із сенсорів є ключовим етапом у роботі автоматизованої системи прогнозування поломок. Вона забезпечує перетворення сирих даних, отриманих із виробничого обладнання, у структурований формат, придатний для аналізу та створення прогнозів. Цей процес включає кілька етапів, кожен з яких виконує конкретні функції, спрямовані на забезпечення високої якості даних і точності прогнозів.

Першим етапом обробки даних є фільтрація та очищення, яка має на меті виявлення аномальних значень, що не відповідають очікуваним параметрам роботи обладнання. Наприклад, у випадку короткочасних збоїв у роботі сенсорів можуть виникати значення, які суттєво відрізняються від нормального діапазону. Для виявлення таких значень використовуються методи статистичного аналізу, такі як обчислення меж інтерквартильного розмаху або побудова моделей на основі середнього та стандартного відхилення.

Другим етапом є імпутація пропущених значень, які можуть виникати через перебої у передачі даних або несправності сенсорів. Для заповнення таких прогалів застосовуються алгоритми інтерполяції (лінійна, сплайнова), методи обчислення ковзного середнього або складніші моделі на основі машинного

навчання, такі як моделі регресії чи рекурентні нейронні мережі. Вибір конкретного підходу залежить від природи даних і частоти запису показників.

Наступним етапом є нормалізація та масштабування даних, що забезпечує приведення параметрів до єдиного масштабу для подальшого аналізу. Це особливо важливо при роботі з даними, що мають різні одиниці виміру, наприклад, температура ($^{\circ}\text{C}$) і струм (A). Найчастіше використовуються методи мінімаксного масштабування, яке зводить значення до діапазону $[0,1]$, або стандартного масштабування, яке нормує значення відносно середнього та стандартного відхилення.

Для обробки часових рядів, характерних для сенсорних даних, застосовується агрегація у часові вікна. Цей процес полягає у групуванні даних у визначені інтервали часу (наприклад, 1 хвилина, 10 хвилин) та обчисленні таких показників, як середнє, мінімум, максимум або медіана. Такий підхід дозволяє скоротити обсяг даних і водночас зберегти їхню інформативність. Наприклад, при аналізі температури двигуна можна розраховувати середнє значення за кожні 5 хвилин, щоб виявляти тенденції нагрівання.

Одним із важливих завдань є виділення характеристик (feature extraction) для побудови моделей прогнозування. Замість роботи з сирими даними сенсорів виділяються характеристики, що більш точно описують стан системи. До таких характеристик можуть належати швидкість зміни параметрів (похідна), коефіцієнти автокореляції, енергетичні характеристики (наприклад, середньоквадратичне значення) тощо. Ці особливості дозволяють моделі краще розрізняти нормальний і аномальний стани.

Особливе місце в алгоритмах обробки даних займає кластеризація та виявлення аномалій, які реалізуються з використанням алгоритму DBSCAN. Цей метод дозволяє групувати дані у кластери на основі щільності розташування точок у багатовимірному просторі. Точки, які не входять до жодного кластера, позначаються як аномалії. Це дає змогу виявляти незвичайні стани системи, які можуть свідчити про потенційні поломки.

Завершальним етапом обробки є підготовка даних для побудови асоціативних правил за допомогою алгоритму Apriori. У цьому контексті дані перетворюються у бінарний формат, де кожна транзакція представляє стан системи у певний момент часу. Наприклад, до набору даних можуть входити такі показники, як «температура $> 90^{\circ}\text{C}$ » або «струм $> 50\text{A}$ », які отримуються внаслідок попередньої обробки.

Таким чином, алгоритми обробки даних із сенсорів забезпечують створення структурованих та якісних даних, необхідних для ефективної роботи системи прогнозування [16]. Вони дозволяють не лише зменшити вплив шуму та пропусків, але й виділити ключові особливості, що забезпечують точність і надійність прогнозів. Ці алгоритми є важливим компонентом усього ланцюга аналізу, спрямованого на забезпечення безперервної роботи виробничого обладнання.

2.3 Застосування часових вікон для ідентифікації закономірностей

Застосування часових вікон є важливим етапом у процесі обробки даних із сенсорів для ідентифікації закономірностей та створення прогнозів. Цей підхід дозволяє структурувати дані, отримані у вигляді часових рядів, та виділити значущі особливості, які слугують основою для побудови моделей прогнозування поломок. Часові вікна забезпечують сегментацію даних у задані інтервали часу, що сприяє оптимізації аналізу та підвищенню точності прогнозів.

Основною ідеєю застосування часових вікон є розподіл даних на непересічні або частково перекриті інтервали часу, у межах яких обчислюються різноманітні агреговані показники. До таких показників належать середнє значення, медіана, мінімум, максимум, стандартне відхилення, швидкість зміни параметра (похідна) тощо. Вибір ширини часових вікон є критичним етапом, оскільки він впливає на здатність системи виявляти короткострокові чи довгострокові закономірності. Наприклад, вузькі вікна дозволяють фіксувати швидкі зміни в роботі обладнання, тоді як широкі – краще описують загальні тенденції.

Часові вікна дозволяють зменшити обсяг даних, зберігаючи їхню інформативність. Замість роботи із сирими даними, які можуть мати високу дискретність (наприклад, показники реєструються щосекунди), система аналізує агреговані значення для кожного вікна. Це не лише оптимізує обчислення, але й зменшує вплив випадкових шумів та пропущених значень. Наприклад, для показника температури двигуна можна розраховувати середнє значення та амплітуду коливань за 10-хвилинні інтервали, що дозволить зосередитися на загальних трендах, а не на одиничних сплесках.

Важливим аспектом застосування часових вікон є їх використання для виявлення аномалій. Аномальні інтервали визначаються на основі відхилень агрегованих показників від їхніх типових значень. Наприклад, якщо середнє значення температури у часовому вікні перевищує заданий поріг, цей інтервал може бути позначений як аномальний. Для ідентифікації таких відхилень можуть використовуватися статистичні методи або алгоритми кластеризації, такі як DBSCAN.

Окрім агрегованих показників, часові вікна дозволяють виділяти додаткові характеристики, які описують зміну параметрів у часі [17]. Однією з таких характеристик є похідна, яка відображає швидкість зміни параметра у межах вікна. Наприклад, різке зростання температури двигуна у короткий проміжок часу може свідчити про ймовірність перегріву. Іншою важливою характеристикою є автокореляція, яка дозволяє оцінити схожість між значеннями параметра на початку та наприкінці вікна.

Застосування часових вікон також відіграє важливу роль у створенні наборів даних для алгоритму Apriori. У межах кожного вікна система аналізує наявність визначених умов, таких як «температура > 90°C» або «струм > 50A», і формує транзакцію, яка включає ці умови як бінарні змінні. Це дозволяє побудувати модель, яка описує причинно-наслідкові зв'язки між параметрами у певні моменти часу.

Ефективність застосування часових вікон залежить від їхньої правильного налаштування, зокрема від ширини вікна та способу агрегування даних.

Наприклад, для виявлення короткострокових змін можуть використовуватися вузькі вікна, такі як 1-60 секунд, тоді як для довгострокових тенденцій доцільно застосовувати вікна тривалістю 1+ хвилин. У деяких випадках може бути використано перекриття між вікнами, що дозволяє уникнути втрати важливої інформації на межах інтервалів.

Таким чином, застосування часових вікон для ідентифікації закономірностей є важливим інструментом у процесі обробки даних із сенсорів. Цей підхід забезпечує структурування даних, зменшує їхній обсяг та виділяє ключові особливості, що використовуються для побудови моделей прогнозування. Використання часових вікон сприяє підвищенню точності та надійності прогнозів, що робить їх невід'ємною частиною автоматизованих систем моніторингу та аналізу даних.

2.4 Обґрунтування вибору алгоритмів машинного навчання

Машинне навчання відкриває широкий спектр можливостей для вирішення задач прогнозування поломок, пропонуючи багатий арсенал алгоритмів, кожен з яких має свої сильні сторони та особливості застосування [18]. Серед них варто виділити класифікаційні моделі, такі як дерева рішень і випадковий ліс, які дозволяють зрозуміти, які саме характеристики обладнання найбільш вагомі для виявлення потенційних несправностей. Більш складні підходи, такі як градієнтний бустинг або нейронні мережі, забезпечують високу точність прогнозів завдяки здатності моделювати складні нелінійні залежності.

Водночас, кластеризаційні методи, такі як K-Means, Mini-Batch K-Means, або навіть Gaussian Mixture Models, пропонують підхід до розподілення даних на групи для ідентифікації типових і нетипових сценаріїв роботи обладнання [19-21]. Проте, у задачах, де обсяг даних може бути значним, а форми кластерів неоднорідними, такі методи часто стикаються з обмеженнями, пов'язаними зі складністю вибору кількості кластерів і нечутливістю до шуму. Для вирішення цих проблем особливо перспективним є алгоритм DBSCAN, який не лише дозволяє виявляти кластери

будь-якої форми, але й автоматично позначає точки, що не належать до жодного кластеру, як шум, що особливо доречно для виявлення аномалій.

Додатково, методи пошуку асоціативних правил, такі як Apriori, грають ключову роль у визначенні зв'язків між різними параметрами роботи обладнання. Завдяки цьому можна не лише встановити, які параметри є критичними для прогнозування поломок, але й зрозуміти, які комбінації факторів найчастіше призводять до аномальних ситуацій. Наприклад, алгоритм Apriori дозволяє визначити, що перевищення певного рівня температури та одночасне зростання струму понад встановлений поріг з великою ймовірністю передують збоєм.

Таким чином, впровадження алгоритмів ML у систему прогнозування поломок забезпечує потужний інструментарій для аналізу даних, ідентифікації потенційних проблем і запобігання несправностям [22]. Гармонійна взаємодія DBSCAN та Apriori створює основу для інтегрованої системи, здатної працювати з великими масивами даних, адаптуватися до мінливих умов і забезпечувати високу точність прогнозів. Це підкреслює важливість ML як ключового компонента сучасних систем моніторингу та аналізу даних.

2.5 Використання теорії автоматичного управління в прогнозуванні поломок

Теорія автоматичного управління є важливим теоретичним підґрунтям для розвитку автоматизованих систем прогнозування поломок, зокрема у виробничих процесах [23-25]. Основні принципи цієї теорії забезпечують ефективне функціонування системи управління шляхом аналізу та адаптації до змінних умов. Застосування методів автоматичного управління дозволяє значно підвищити точність і надійність прогнозів, а також скоротити час реакції на потенційні збої.

У прогнозуванні поломок ключовим є принцип зворотного зв'язку, який забезпечує адаптацію системи до змінних параметрів технологічного процесу. Це досягається шляхом аналізу поточного стану системи, виявлення відхилень і внесення відповідних коректив. Наприклад, у системах прогнозування поломок, заснованих на асоціативних правилах, дані з сенсорів аналізуються в реальному

часі, а ідентифіковані закономірності дозволяють автоматично коригувати модель прогнозування.

Динамічні аспекти процесу управління відіграють вирішальну роль у визначенні часових вікон для аналізу даних. Теорія автоматичного управління пропонує методи моделювання, які дозволяють враховувати інерційність процесів і затримки в реакції системи. Це особливо актуально для систем, які потребують прогнозування подій у реальному часі.

Застосування методів оптимізації, що базуються на принципах автоматичного управління, забезпечує вибір найкращих параметрів системи. Наприклад, налаштування параметрів алгоритмів DBSCAN та Apriori може бути виконано з урахуванням специфіки виробничих процесів, що дозволяє мінімізувати хибно-позитивні прогнози і водночас забезпечити високу чутливість до потенційних поломок.

Таким чином, теорія автоматичного управління не лише створює основу для побудови систем прогнозування, але й забезпечує їхню інтеграцію у складні виробничі середовища [26-27]. Вона дозволяє розробляти системи, здатні до адаптації, що підвищує їх ефективність та знижує ймовірність виникнення аварійних ситуацій.

2.6 Висновки до другого розділу

У другому розділі розглянуто процес розробки системи прогнозування поломок, включаючи її архітектуру, алгоритми обробки даних із сенсорів та застосування часових вікон для ідентифікації закономірностей. Запропонована архітектура системи є багаторівневою, модульною та адаптивною до змін виробничого середовища, що забезпечує її гнучкість і масштабованість [28]. Вона включає етапи попередньої обробки, аналізу та візуалізації даних, а також підтримує інтеграцію сучасних алгоритмів машинного навчання.

Алгоритми обробки даних із сенсорів забезпечують трансформацію сирих даних у якісний формат, придатний для аналізу. У процесі обробки виконуються

такі важливі операції, як очищення даних, заповнення пропущених значень, нормалізація, а також виділення характеристик. Це дозволяє забезпечити точність та надійність даних, що є основою для побудови прогнозних моделей.

Особливу увагу приділено застосуванню часових вікон для сегментації та агрегування даних. Цей підхід дозволяє структурувати часові ряди, виділити ключові особливості та виявити закономірності, що характерні для нормального або аномального стану обладнання. Часові вікна також забезпечують ефективну підготовку даних для використання алгоритмів DBSCAN і Apriori, які є ключовими у системі прогнозування.

Розроблена система прогнозування поломок демонструє високий рівень адаптивності до різноманітних умов виробництва, завдяки чому може бути впроваджена на підприємствах із різними масштабами діяльності та типами обладнання. Інтеграція сучасних алгоритмів обробки та аналізу даних забезпечує точність прогнозів і дозволяє запобігти виникненню аварійних ситуацій. Таким чином, результати другого розділу формують основу для практичної реалізації автоматизованої системи прогнозування, спрямованої на підвищення ефективності та безпеки виробничих процесів.

3 РОЗРОБЛЕННЯ ПРОГРАМНОГО ЗАСТОСУНКУ ДЛЯ ПРОГНОЗУВАННЯ ПОЛОМОК

3.1 Вимоги до програмного забезпечення

Вимоги до програмного забезпечення для системи прогнозування поломок є основою для його ефективного проєктування, розробки та впровадження. Ці вимоги охоплюють широкий спектр аспектів, включаючи функціональні, технічні, операційні та нефункціональні характеристики, які забезпечують надійність, точність і зручність використання системи. Програмне забезпечення буде реалізоване повністю на мові програмування Python, що забезпечує високу швидкість розробки, простоту інтеграції з численними бібліотеками для аналізу даних та візуалізації, а також підтримку кросплатформності [29-31].

Функціональні вимоги визначають ключові можливості програмного забезпечення, такі як очищення даних від шуму та заповнення пропущених значень. Система має забезпечувати нормалізацію показників, їх агрегацію у часові вікна та створення наборів даних для алгоритмів DBSCAN і Apriori. Основними функціями є ідентифікація аномалій, формування асоціативних правил для прогнозування поломок і візуалізація даних через інтерактивні графіки. Вибір Python дозволяє використовувати потужні бібліотеки, такі як pandas, scikit-learn, matplotlib та mlxtend, що гарантує надійність алгоритмів обробки даних і їх зручну інтеграцію.

Технічні вимоги акцентують увагу на продуктивності, масштабованості та безпеці. Програмне забезпечення повинно працювати на операційних системах Windows 10/11, а також мати потенціал розгортання у хмарних середовищах, таких як Azure або AWS. Масштабованість є критично важливою для забезпечення адаптації до зростаючого обсягу даних і збільшення кількості сенсорів на виробничому обладнанні. Використання Python дозволяє інтегрувати систему з

такими технологіями, як сервери Flask для розгортання API або хмарні обчислювальні середовища, які підтримують Python.

Операційні вимоги спрямовані на створення зручного та інтуїтивно зрозумілого інтерфейсу користувача, який дозволяє працівникам різного рівня кваліфікації ефективно взаємодіяти із системою. Інтерфейс, розроблений за допомогою бібліотеки PyQt або аналогів, забезпечує просту навігацію та доступ до ключових функцій, включаючи перегляд даних, графіків і сповіщень [32]. Для полегшення інтеграції системи на виробництві розробляється детальна документація, що включає інструкції з використання та рекомендації щодо експлуатації. Програмне забезпечення також має бути сумісним із середньостатистичним апаратним забезпеченням без необхідності його модернізації, що забезпечує мінімальні витрати на впровадження.

Нефункціональні вимоги охоплюють аспекти якості програмного забезпечення, такі як надійність, гнучкість, модульність та зрозумілість коду. Система має працювати стабільно, забезпечуючи прогнозування поломок у режимі реального часу. Архітектура програмного забезпечення розробляється модульною, що дозволяє здійснювати оновлення окремих компонентів без порушення роботи всієї системи. Використання Python сприяє зниженню складності коду завдяки його читабельності та великій кількості інструментів для тестування. Крім того, структура коду забезпечує його легкість для розуміння та підтримки, що знижує витрати на майбутні оновлення та масштабування. Дотримання цих вимог дозволяє створити надійне, функціональне та адаптивне програмне забезпечення, здатне задовольнити потреби сучасного виробництва та підвищити ефективність і безпеку виробничих процесів.

3.2 Інтерфейс користувача для введення параметрів аналізу

Інтерфейс користувача для введення параметрів аналізу є ключовим компонентом програмного забезпечення, що забезпечує зручну взаємодію оператора із системою прогнозування поломок. Його головна мета полягає у

спрощенні процесу налаштування параметрів аналізу та забезпеченні інтуїтивного доступу до ключових функцій. Оскільки система працює із широким спектром параметрів, таких як підтримка (support), впевненість (confidence), приріст (lift) та інші, інтерфейс має бути розроблений таким чином, щоб максимально полегшити введення, перевірку та збереження значень [33-34].

Особлива увага приділяється валідації введених даних. Якщо користувач вводить значення, що не відповідає допустимому діапазону, інтерфейс відображає попередження із зазначенням помилки та рекомендацією щодо правильного введення. Це дозволяє уникнути помилок на етапі налаштування аналізу.

Для забезпечення зручності роботи з великими обсягами даних інтерфейс також включає секцію вибору джерела даних. Користувач може завантажити файл із даними у форматі CSV. Завантаження файлу супроводжується попередньою перевіркою структури даних, яка визначає, чи відповідає формат вхідного файлу необхідним вимогам.

Важливим елементом інтерфейсу є кнопка запуску аналізу, яка активує виконання алгоритмів обробки даних та формування прогнозів. Перед запуском система перевіряє, чи всі необхідні параметри задано, та, у разі відсутності будь-яких значень, повідомляє про це користувача. Після початку аналізу інтерфейс відображає прогрес виконання через індикатор виконання, який дозволяє оператору оцінювати тривалість процесу.

Додатково інтерфейс включає секцію відображення поточних результатів, де після виконання аналізу користувач може переглядати виявлені закономірності, сформовані асоціативні правила та виявлені аномалії. Інтуїтивний дизайн цієї секції дозволяє швидко оцінювати результати та приймати рішення щодо подальших дій.

Таким чином, інтерфейс користувача розробляється з урахуванням потреб операторів виробничих систем і забезпечує простоту, точність та зручність введення параметрів аналізу. Його функціональність спрямована на мінімізацію помилок, підвищення ефективності роботи та інтеграцію всіх необхідних інструментів для забезпечення високої якості прогнозування поломок.

Приклад реалізації інтерфейсу з проєкту наведено на рис. 3.1.

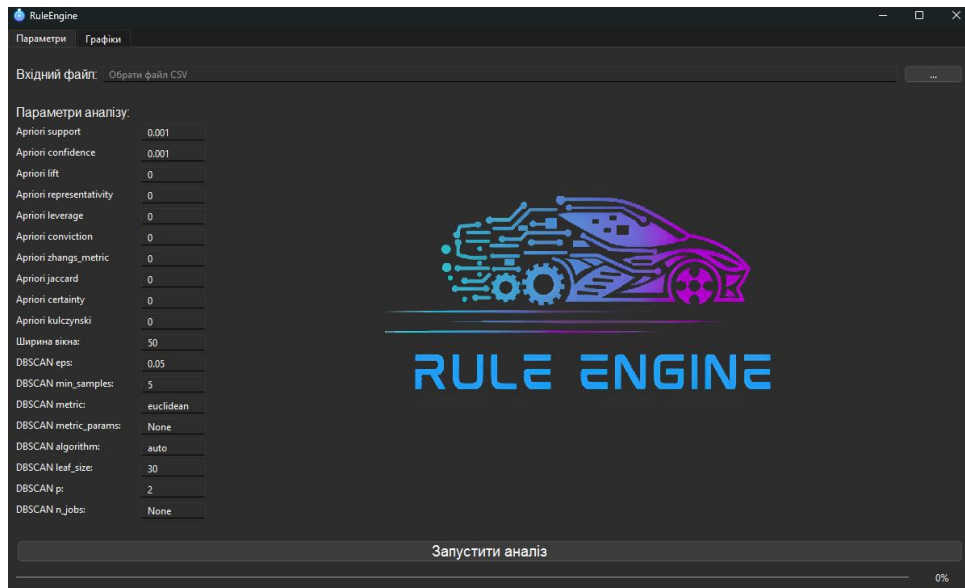


Рисунок 3.1 – Інтерфейс користувача

3.3 Реалізація інтеграції алгоритмів DBSCAN та Apriori

Реалізація інтеграції алгоритмів DBSCAN та Apriori є ключовим аспектом побудови автоматизованої системи прогнозування поломок. Ця інтеграція спрямована на поєднання можливостей кластеризації та виявлення аномалій алгоритмом DBSCAN із потужними засобами генерації асоціативних правил алгоритму Apriori. Результатом є система, здатна не лише виявляти потенційно небезпечні стани обладнання, але й формувати прогностичні правила, які дозволяють ідентифікувати закономірності у роботі системи.

На початковому етапі інтеграції здійснюється обробка даних, отриманих із сенсорів. Алгоритм DBSCAN застосовується до набору даних, який містить часові мітки, параметри роботи обладнання та агреговані показники, такі як середнє, максимум чи стандартне відхилення в межах часових вікон. DBSCAN виконує кластеризацію даних на основі щільності точок у багатовимірному просторі, де кожен параметр є однією з координат [35-36]. Головною перевагою DBSCAN є здатність виділяти аномальні точки, які не входять до жодного кластеру, що є

важливим для ідентифікації несправностей. Код функції для кластеризації за допомогою методу DBSCAN наведено нижче:

```
def dbscan_anomaly(df, eps, min_samples, metric, metric_params, algorithm,
leaf_size, p, n_jobs):
    """
    Performs DBSCAN on (timestamp_ordinal, value).
    cluster=-1 => anomaly.
    """
    # Sort & interpolate
    df = df.sort_values(["device", "metric", "timestamp"]).copy()
    df["value"] = df.groupby(["device", "metric"])["value"].transform(lambda x:
x.interpolate(method="linear"))
    df = df.dropna().copy()
    # DBSCAN
    df["timestamp_ordinal"] = df["timestamp"].map(pd.Timestamp.toordinal)
    dbs_model = DBSCAN(eps=eps, min_samples=min_samples, metric=metric,
metric_params=metric_params, algorithm=algorithm,
leaf_size=leaf_size, p=p, n_jobs=n_jobs)
    df["cluster"] = dbs_model.fit_predict(df[["timestamp_ordinal", "value"]])
    df["anomaly"] = (df["cluster"] == -1).astype(int)
    return df
```

Після виконання кластеризації результати DBSCAN інтегруються у наступний етап аналізу. Для кожного часового вікна визначаються, чи містить воно аномальні точки, та створюється бінарна змінна, що позначає їхню наявність. Наприклад, якщо у певному вікні кілька точок позначені як аномальні, це вікно вважається потенційно проблемним і використовується у подальшому аналізі.

Наступний крок інтеграції полягає у підготовці даних для алгоритму Apriori. На цьому етапі кожне часове вікно перетворюється у транзакцію, яка містить

інформацію про виявлені аномалії та значення параметрів, що відповідають певним умовам. Наприклад, у наборі даних можуть бути представлені такі елементи, як «температура > 80°C» або «струм > 50А». Ці дані подаються у форматі, що підтримується алгоритмом Apriori, де кожен елемент транзакції позначається бінарно: 1 – умова виконується, 0 – не виконується.

Алгоритм Apriori, працюючи з підготовленими даними, генерує часті набори елементів та формує асоціативні правила, які описують залежності між параметрами. Наприклад, одним із правил може бути: «Якщо температура двигуна перевищує 90°C та струм більший за 60А, то з імовірністю 85% виникне аномалія». Такі правила дозволяють не лише пояснювати поточні стани обладнання, але й прогнозувати майбутні несправності. Код функції для розрахунку асоціативних правил за допомогою алгоритму Apriori наведено нижче:

```
def run_apriori(pivot_data, support, confidence, lift=0, leverage=0, conviction=0,
               zhangs_metric=0, jaccard=0, certainty=0, kulczynski=0):
    data_for_apriori = pivot_data.drop(columns=["timestamp"]).astype(bool)
    freq_itemsets = apriori(data_for_apriori, min_support=support,
                             use_colnames=True)
    if freq_itemsets.empty:
        return pd.DataFrame()
    rules_ = association_rules(
        freq_itemsets,
        metric="confidence",
        min_threshold=confidence,
        num_itemsets=len(freq_itemsets)
    )
    if lift > 0:
        rules_ = rules_[rules_["lift"] >= lift]
    if leverage > 0:
        rules_ = rules_[rules_["leverage"] >= leverage]
```

```

if conviction > 0:
    rules_ = rules_[rules_["conviction"] >= conviction]
if zhangs_metric > 0:
    rules_ = rules_[rules_["zhangs_metric"] >= zhangs_metric]
if jaccard > 0:
    rules_ = rules_[rules_["jaccard"] >= jaccard]
if certainty > 0:
    rules_ = rules_[rules_["certainty"] >= certainty]
if kulczynski > 0:
    rules_ = rules_[rules_["kulczynski"] >= kulczynski]
return rules_.sort_values("confidence", ascending=False)

```

Особливу увагу приділяють оптимізації параметрів обох алгоритмів. Для DBSCAN критично важливими є параметри `eps` (радіус сусідства) та `min_samples` (мінімальна кількість точок для утворення кластеру). Їх підбирають експериментально на основі характеристик даних, щоб мінімізувати хибнопозитивні та хибнонегативні результати. Для Apriori загалом опираються на значення підтримки (`support`), впевненості (`confidence`) та приросту (`lift`), що дозволяють виділяти лише релевантні правила.

Інтеграція алгоритмів DBSCAN та Apriori реалізується у вигляді модульної структури, що забезпечує гнучкість та масштабованість. Обидва алгоритми працюють як незалежні компоненти, які взаємодіють через спільну базу даних. Це дозволяє легко адаптувати систему до змін у параметрах виробничого процесу або додавання нових сенсорів.

Підсумовуючи, інтеграція алгоритмів DBSCAN та Apriori створює потужний інструмент для аналізу сенсорних даних та прогнозування поломок. Вона поєднує переваги кластеризації для виявлення аномалій із генерацією асоціативних правил для ідентифікації закономірностей. Такий підхід дозволяє значно підвищити ефективність роботи системи, зменшити кількість несправностей та забезпечити безпеку виробничих процесів.

3.4 Візуалізація результатів

Візуалізація результатів є важливим компонентом автоматизованої системи прогнозування поломок, оскільки вона забезпечує зручне та інтуїтивно зрозуміле представлення даних, що дозволяє користувачам ефективно аналізувати результати роботи системи та приймати обґрунтовані рішення. Основною метою візуалізації є надання графічних інструментів для відображення ключових показників, ідентифікованих аномалій, асоціативних правил та прогнозів щодо можливих поломок [37].

Головним елементом візуалізації є графіки, які відображають динаміку основних параметрів роботи обладнання у часі. В застосунку існує окрема вкладка для перегляду графіків, також варто відзначити, що усі графіки зберігаються у папку Charts поточного проєкту.

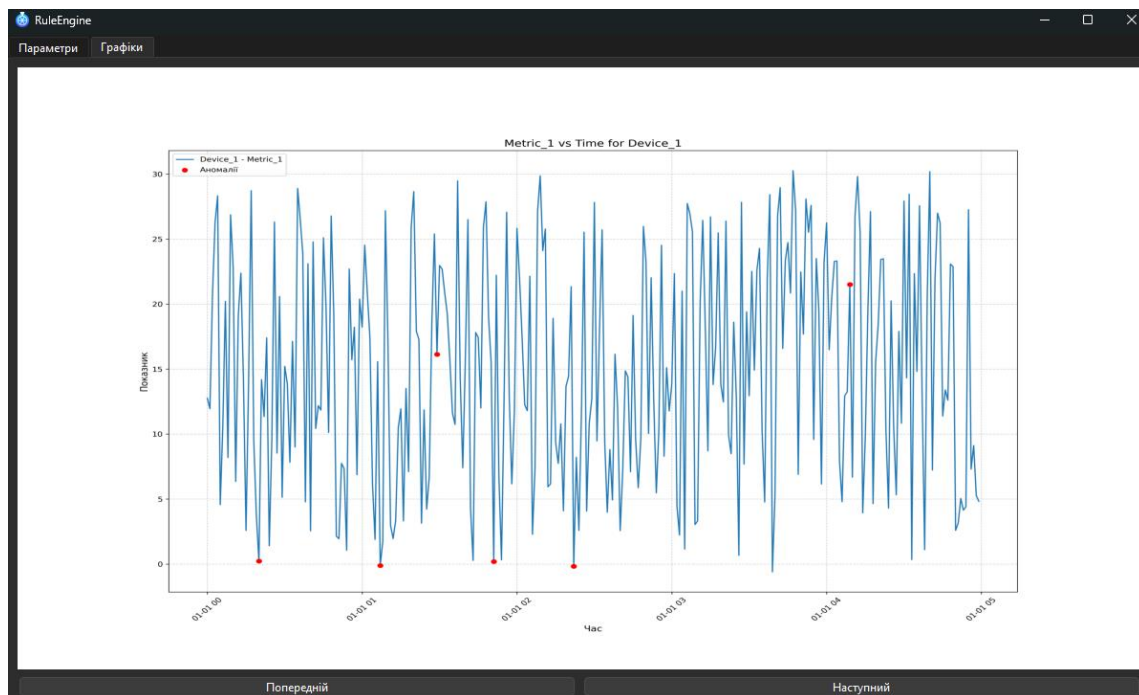


Рисунок 3.2 – Приклад інтерфейсу застосунку для виводу графіків

Для кожного сенсора будується окремий графік, на якому показуються значення параметра у вигляді лінійного графіка. На таких графіках аномалії, визначені алгоритмом DBSCAN, позначаються спеціальними маркерами,

наприклад, червоними точками, що дозволяє легко ідентифікувати небезпечні стани. Приклади зображені на рис. 3.3 – 3.5.

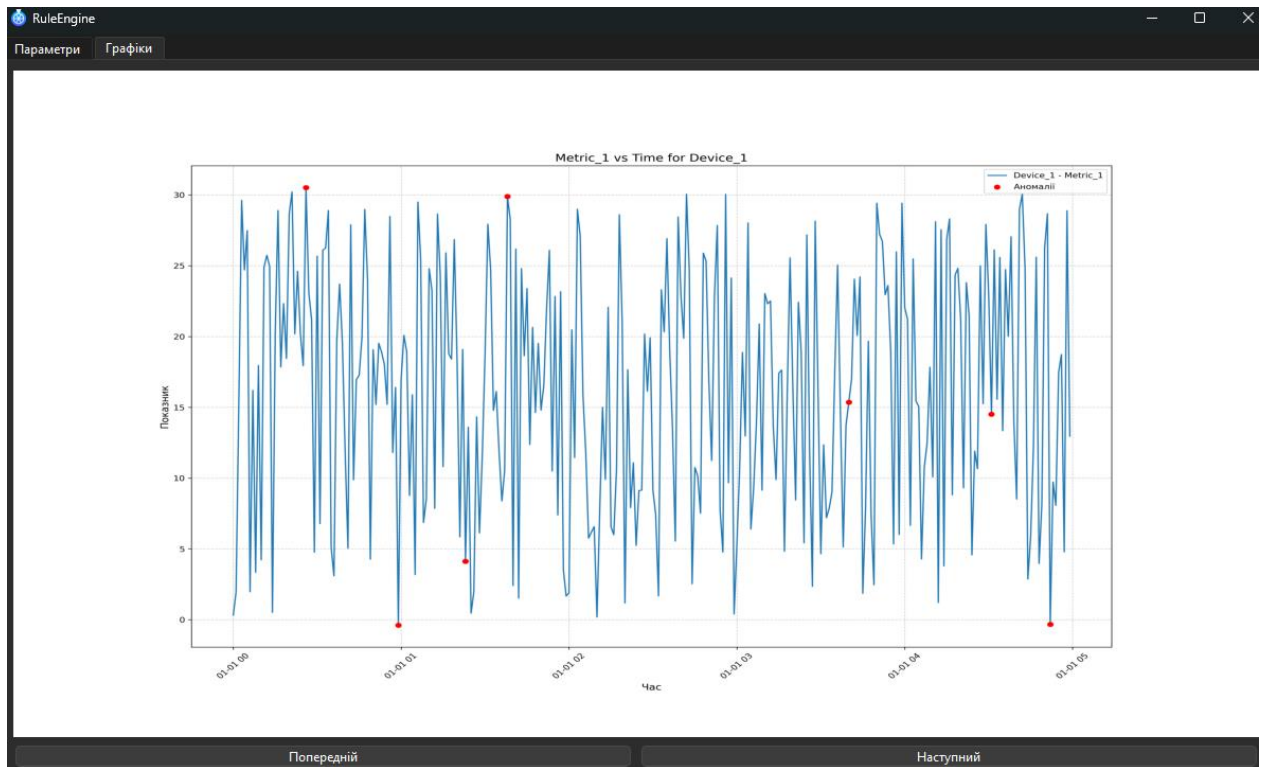


Рисунок 3.3 – Залежність показника Metric_1 від часу для Device_1

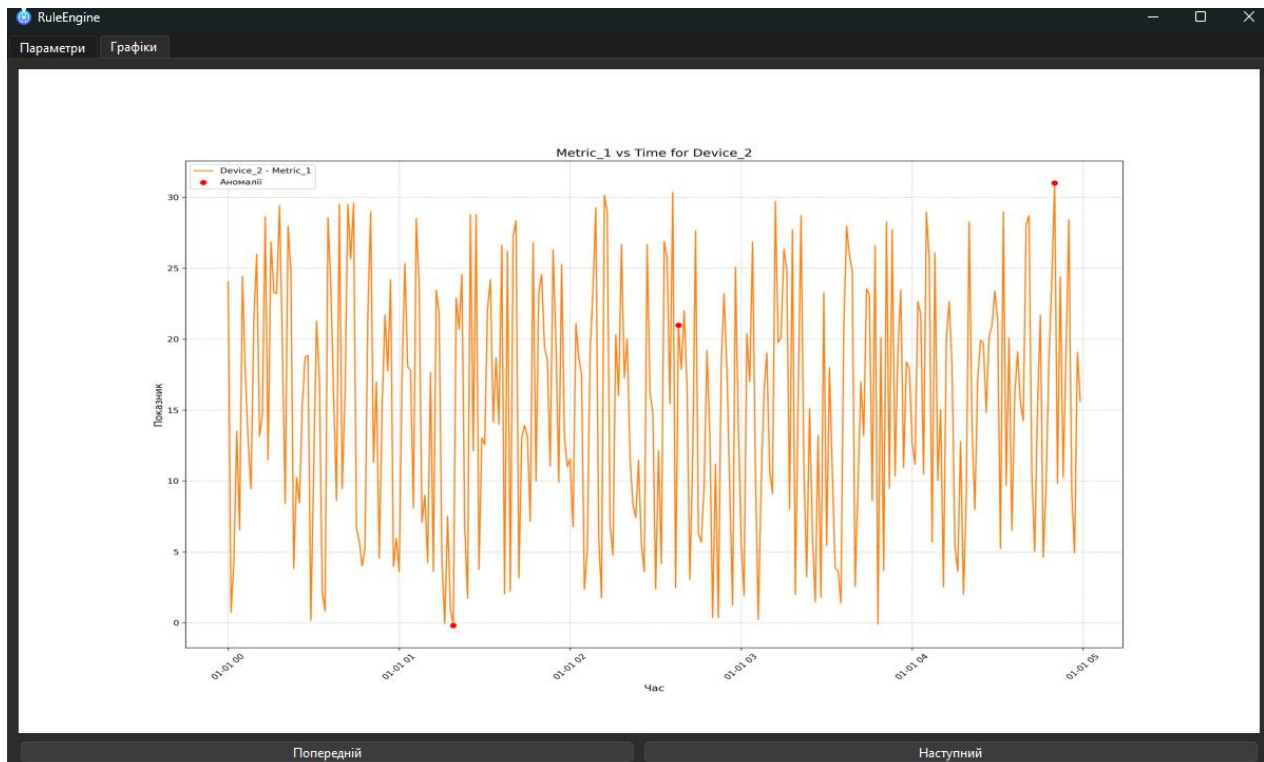


Рисунок 3.4 – Залежність показника Metric_1 від часу для Device_2




Рисунок 3.5 – Залежність показника Metric_1 від часу для Device_3

Крім того, система може додатково відобразити залежність аномалії до часу для кожного пристрою, приклад чого наведено у рис. 3.6 – 3.8.




Рисунок 3.6 – Залежність часу до аномалії від часу для Device_1




Рисунок 3.7 – Залежність часу до аномалії від часу для Device_2




Рисунок 3.8 – Залежність часу до аномалії від часу для Device_3

Для підвищення ефективності роботи користувачів візуалізація результатів реалізується таким чином, щоб відповідати принципам інтуїтивності та

мінімального когнітивного навантаження. Кольорові схеми, розміщення елементів та стилі графіків розробляються з урахуванням рекомендацій з ергономіки та сучасного дизайну. Це забезпечує легкість сприйняття інформації та зменшує ймовірність помилок у процесі прийняття рішень.

Таким чином, візуалізація результатів у системі прогнозування поломок є не лише інструментом для представлення даних, але й важливою складовою частиною інтерфейсу користувача. Вона сприяє ефективному використанню системи, надаючи зрозумілий та інформативний доступ до аналітичної інформації, що підвищує якість управління виробничими процесами та мінімізує ризики поломок.

3.5 Висновки до третього розділу

У третьому розділі було детально розглянуто процес розробки програмного застосунку для прогнозування поломок на основі інтеграції алгоритмів DBSCAN та Apriori [38]. Розроблений програмний продукт відповідає сучасним вимогам до систем такого типу, забезпечуючи високу функціональність, зручність використання та адаптивність до умов виробничого середовища.

Особливу увагу приділено визначенню вимог до програмного забезпечення, які охоплюють функціональні, технічні, операційні та нефункціональні аспекти. Це забезпечує надійну роботу системи, її інтеграцію з існуючими інфраструктурами та підтримку ефективного моніторингу даних із сенсорів у реальному часі. Програмний застосунок створено з урахуванням потреб операторів, що сприяє мінімізації помилок та підвищенню ефективності управління процесами.

Реалізація інтеграції алгоритмів DBSCAN та Apriori стала ключовим етапом, який дозволив поєднати можливості кластеризації даних для виявлення аномалій із генерацією асоціативних правил для прогнозування поломок. Цей підхід забезпечує високу точність аналізу та дає змогу створювати прогнозні моделі, що відповідають реальним виробничим процесам. Використання часових вікон дозволило структурувати дані та покращити результати роботи алгоритмів.

Детально опрацьовано питання візуалізації результатів, яка забезпечує зручний та інтуїтивно зрозумілий доступ до аналітичної інформації. Інтерактивні графіки, модулі для перегляду асоціативних правил сприяють швидкому прийняттю рішень щодо запобігання поломок. Візуалізація також забезпечує можливість експорту результатів для подальшого використання у звітах та аналізах.

Таким чином, розроблений програмний застосунок демонструє високий рівень технологічності та ефективності, дозволяючи підвищити надійність виробничого обладнання та зменшити витрати, пов'язані з несправностями. Висновки, зроблені у цьому розділі, підтверджують практичну цінність створеної системи та її перспективи для впровадження у виробничих умовах.

4 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ

4.1. Практичний експеримент

Для експериментального дослідження були згенеровані тестові дані, що імітують роботу трьох пристроїв, кожен із яких вимірював три різні показники протягом 5 хвилин з інтервалом 1 мс. Дані містили штучно додані аномалії. Це дозволило змоделювати ситуації, коли пристрої працюють із порушеннями, характерними для початкових або кінцевих етапів роботи.

Отримані результати занесені до таблиці, яка ілюструє перші рядки синтетично згенерованих даних. Ці дані проходять початкове форматування та додається стовпець «manual_anomaly» з можливістю вручну занести аномалії в певні проміжки часу, якщо алгоритм не зміг виявити конкретну аномалію про яку відомо. Приклад зображено на рис. 4.1.

| timestamp | device | metric | value | manual_anomaly |
|-----------------|----------|----------|--------------------|----------------|
| 01.01.2025 0:00 | Device_1 | Metric_1 | 11.272661037343925 | 0 |
| 01.01.2025 0:01 | Device_1 | Metric_1 | 28.000148914212833 | 0 |
| 01.01.2025 0:02 | Device_1 | Metric_1 | 23.674973525802415 | 0 |
| 01.01.2025 0:03 | Device_1 | Metric_1 | 18.466889743765506 | 0 |
| 01.01.2025 0:04 | Device_1 | Metric_1 | 3.06044514394701 | 0 |
| 01.01.2025 0:05 | Device_1 | Metric_1 | 4.828999061901621 | 0 |
| 01.01.2025 0:06 | Device_1 | Metric_1 | 1.2130791932312734 | 0 |
| 01.01.2025 0:07 | Device_1 | Metric_1 | 26.667231041085035 | 0 |
| 01.01.2025 0:08 | Device_1 | Metric_1 | 17.399433761550103 | 0 |
| 01.01.2025 0:09 | Device_1 | Metric_1 | 21.150388180707846 | 0 |
| 01.01.2025 0:10 | Device_1 | Metric_1 | 1.0215246520584391 | 0 |
| 01.01.2025 0:11 | Device_1 | Metric_1 | 29.78989972019593 | 0 |
| 01.01.2025 0:12 | Device_1 | Metric_1 | 24.013042098368032 | 0 |
| 01.01.2025 0:13 | Device_1 | Metric_1 | 6.102572331675526 | 0 |
| 01.01.2025 0:14 | Device_1 | Metric_1 | 5.074792767284253 | 0 |
| 01.01.2025 0:15 | Device_1 | Metric_1 | 4.979471909544046 | 0 |
| 01.01.2025 0:16 | Device_1 | Metric_1 | 10.53963068101101 | 0 |
| 01.01.2025 0:17 | Device_1 | Metric_1 | 16.0666783177359 | 0 |
| 01.01.2025 0:18 | Device_1 | Metric_1 | 11.949643395795436 | 0 |
| 01.01.2025 0:19 | Device_1 | Metric_1 | 9.471163763585078 | 0 |
| 01.01.2025 0:20 | Device_1 | Metric_1 | 20.05331179928149 | 0 |
| 01.01.2025 0:21 | Device_1 | Metric_1 | 5.010788028002173 | 0 |
| 01.01.2025 0:22 | Device_1 | Metric_1 | 7.548843483293334 | 0 |

Рисунок 4.1 – Початкові дані для подальшої обробки

Наступним кроком за допомогою алгоритму DBSCAN відбувається кластеризація цих значень на два кластери Normal та Anomaly. Приклад цих даних зображено на рис. 4.2

| timestamp | device | metric | value | manual_anomaly | timestamp_ordinal | cluster | anomaly | ClusterName |
|-----------------|----------|----------|--------------------|----------------|-------------------|---------|---------|-------------|
| 01.01.2025 0:47 | Device_1 | Metric_1 | 15.293789757844916 | 0 | 739252 | 0 | 0 | Normal |
| 01.01.2025 0:48 | Device_1 | Metric_1 | 16.492122256499385 | 0 | 739252 | 0 | 0 | Normal |
| 01.01.2025 0:49 | Device_1 | Metric_1 | 6.075338205382648 | 0 | 739252 | 0 | 0 | Normal |
| 01.01.2025 0:50 | Device_1 | Metric_1 | 30.35635228585304 | 0 | 739252 | -1 | 1 | Anomaly |
| 01.01.2025 0:51 | Device_1 | Metric_1 | 22.263732301771956 | 0 | 739252 | 0 | 0 | Normal |
| 01.01.2025 0:52 | Device_1 | Metric_1 | 29.89139494665069 | 0 | 739252 | 0 | 0 | Normal |
| 01.01.2025 0:53 | Device_1 | Metric_1 | 25.28315027321146 | 0 | 739252 | 0 | 0 | Normal |
| 01.01.2025 0:54 | Device_1 | Metric_1 | 17.81557128830409 | 0 | 739252 | 0 | 0 | Normal |
| 01.01.2025 0:55 | Device_1 | Metric_1 | 28.176880815881165 | 0 | 739252 | 0 | 0 | Normal |

Рисунок 4.2 – Кластеризовані початкові дані

Для прогнозної аналітики часу настання аномалій необхідно взяти унікальний час для аномалій та знайти найближчу до кожного рядка [39]. Приклад цього зображено на рис. 4.3.

| timestamp | device | metric | value | manual_anomaly | timestamp_ordinal | cluster | anomaly | ClusterName | time_to_anomaly | AnomalyFutureEvent |
|-----------------|----------|----------|--------------------|----------------|-------------------|---------|---------|-------------|-----------------|--------------------|
| 01.01.2025 0:00 | Device_1 | Metric_1 | 11.272661037343925 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 |
| 01.01.2025 0:01 | Device_1 | Metric_1 | 28.000148914212833 | 0 | 739252 | 0 | 0 | Normal | 0.0 | 1 |
| 01.01.2025 0:02 | Device_1 | Metric_1 | 23.674973525802415 | 0 | 739252 | 0 | 0 | Normal | 300.0 | 1 |
| 01.01.2025 0:03 | Device_1 | Metric_1 | 18.466889743765506 | 0 | 739252 | 0 | 0 | Normal | 240.0 | 1 |
| 01.01.2025 0:04 | Device_1 | Metric_1 | 3.06044514394701 | 0 | 739252 | 0 | 0 | Normal | 180.0 | 1 |
| 01.01.2025 0:05 | Device_1 | Metric_1 | 4.828999061901621 | 0 | 739252 | 0 | 0 | Normal | 120.0 | 1 |
| 01.01.2025 0:06 | Device_1 | Metric_1 | 1.2130791932312734 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 |
| 01.01.2025 0:07 | Device_1 | Metric_1 | 26.667231041085035 | 0 | 739252 | 0 | 0 | Normal | 0.0 | 1 |
| 01.01.2025 0:08 | Device_1 | Metric_1 | 17.399433761550103 | 0 | 739252 | 0 | 0 | Normal | 300.0 | 1 |
| 01.01.2025 0:09 | Device_1 | Metric_1 | 21.150388180707846 | 0 | 739252 | 0 | 0 | Normal | 240.0 | 1 |
| 01.01.2025 0:10 | Device_1 | Metric_1 | 1.0215246520584391 | 0 | 739252 | 0 | 0 | Normal | 180.0 | 1 |
| 01.01.2025 0:11 | Device_1 | Metric_1 | 29.78989972019593 | 0 | 739252 | 0 | 0 | Normal | 120.0 | 1 |
| 01.01.2025 0:12 | Device_1 | Metric_1 | 24.013042098368032 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 |
| 01.01.2025 0:13 | Device_1 | Metric_1 | 6.102572331675526 | 0 | 739252 | 0 | 0 | Normal | 0.0 | 1 |
| 01.01.2025 0:14 | Device_1 | Metric_1 | 5.074792767284253 | 0 | 739252 | 0 | 0 | Normal | 300.0 | 1 |
| 01.01.2025 0:15 | Device_1 | Metric_1 | 4.979471909544046 | 0 | 739252 | 0 | 0 | Normal | 240.0 | 1 |
| 01.01.2025 0:16 | Device_1 | Metric_1 | 10.53963068101101 | 0 | 739252 | 0 | 0 | Normal | 180.0 | 1 |
| 01.01.2025 0:17 | Device_1 | Metric_1 | 16.0666783177359 | 0 | 739252 | 0 | 0 | Normal | 120.0 | 1 |
| 01.01.2025 0:18 | Device_1 | Metric_1 | 11.949643395795436 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 |
| 01.01.2025 0:19 | Device_1 | Metric_1 | 9.471163763585078 | 0 | 739252 | 0 | 0 | Normal | 0.0 | 1 |
| 01.01.2025 0:20 | Device_1 | Metric_1 | 20.05331179928149 | 0 | 739252 | 0 | 0 | Normal | 180.0 | 1 |
| 01.01.2025 0:21 | Device_1 | Metric_1 | 5.010788028002173 | 0 | 739252 | 0 | 0 | Normal | 120.0 | 1 |
| 01.01.2025 0:22 | Device_1 | Metric_1 | 7.548843483293334 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 |

Рисунок 4.3 – Дані з визначеними проміжками до аномалій

В подальшому на основі інформації про аномалії оператор обирає межі показників з метою зручного перетворення даних для генерації асоціативних правил. Приклад визначення меж та вигляд даних в такому випадку зображені на рис. 4.4.

| timestamp | device | metric | value | manual_anomaly | timestamp_ordinal | cluster | anomaly | ClusterName | time_to_anomaly | AnomalyFutureEvent | Dev1_M1_Above25 | Dev2_M3_Below10 | Dev3_M2_Above20 | AnomalyNow |
|-----------------|----------|----------|--------------------|----------------|-------------------|---------|---------|-------------|-----------------|--------------------|-----------------|-----------------|-----------------|------------|
| 01.01.2025 0:00 | Device_1 | Metric_1 | 11.272661037343925 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:01 | Device_1 | Metric_1 | 28.000148914212833 | 0 | 739252 | 0 | 0 | Normal | 0.0 | 1 | 1 | 0 | 0 | 0 |
| 01.01.2025 0:02 | Device_1 | Metric_1 | 23.674973525802415 | 0 | 739252 | 0 | 0 | Normal | 300.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:03 | Device_1 | Metric_1 | 18.466889743765506 | 0 | 739252 | 0 | 0 | Normal | 240.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:04 | Device_1 | Metric_1 | 3.06044514394701 | 0 | 739252 | 0 | 0 | Normal | 180.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:05 | Device_1 | Metric_1 | 4.828999061901621 | 0 | 739252 | 0 | 0 | Normal | 120.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:06 | Device_1 | Metric_1 | 1.2130791932312734 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:07 | Device_1 | Metric_1 | 26.667231041085035 | 0 | 739252 | 0 | 0 | Normal | 0.0 | 1 | 1 | 0 | 0 | 0 |
| 01.01.2025 0:08 | Device_1 | Metric_1 | 17.399433761550103 | 0 | 739252 | 0 | 0 | Normal | 300.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:09 | Device_1 | Metric_1 | 21.150388180707846 | 0 | 739252 | 0 | 0 | Normal | 240.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:10 | Device_1 | Metric_1 | 1.0215246520584391 | 0 | 739252 | 0 | 0 | Normal | 180.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:11 | Device_1 | Metric_1 | 29.78989972019593 | 0 | 739252 | 0 | 0 | Normal | 120.0 | 1 | 1 | 0 | 0 | 0 |
| 01.01.2025 0:12 | Device_1 | Metric_1 | 24.013042098368032 | 0 | 739252 | 0 | 0 | Normal | 60.0 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:13 | Device_1 | Metric_1 | 6.102572331675526 | 0 | 739252 | 0 | 0 | Normal | 0.0 | 1 | 0 | 0 | 0 | 0 |

Рисунок 4.4 – Дані з умовами по показникам датчиків

Передостаннім кроком перед генерацією асоціативних правил є приведення значень у бінарний формат. В ході цього отримуємо дані, які зображені на рис. 4.5.

| A | B | C | D | E | F |
|-----------------|--------------------|-----------------|-----------------|-----------------|------------|
| timestamp | AnomalyFutureEvent | Dev1_M1_Above25 | Dev2_M3_Below10 | Dev3_M2_Above20 | AnomalyNow |
| 01.01.2025 0:00 | 1 | 0 | 1 | 0 | 0 |
| 01.01.2025 0:01 | 1 | 1 | 1 | 0 | 1 |
| 01.01.2025 0:02 | 1 | 0 | 0 | 1 | 0 |
| 01.01.2025 0:03 | 1 | 0 | 0 | 1 | 0 |
| 01.01.2025 0:04 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:05 | 1 | 0 | 1 | 0 | 0 |
| 01.01.2025 0:06 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:07 | 1 | 1 | 0 | 1 | 1 |
| 01.01.2025 0:08 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:09 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:10 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:11 | 1 | 1 | 0 | 0 | 0 |
| 01.01.2025 0:12 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:13 | 1 | 0 | 0 | 1 | 1 |
| 01.01.2025 0:14 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:15 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:16 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:17 | 1 | 0 | 0 | 0 | 0 |
| 01.01.2025 0:18 | 1 | 0 | 1 | 1 | 0 |
| 01.01.2025 0:19 | 1 | 0 | 0 | 0 | 1 |
| 01.01.2025 0:20 | 1 | 0 | 0 | 1 | 0 |

Рисунок 4.5 – Дані з визначеними проміжками до аномалій

Останнім кроком з цього файлу генеруються асоціативні правила та відбувається деталізація цих правил на основі умов та вікон. Приклад результату наведено на рис. 4.6 – 4.7.

| Column1 | column2 | column3 | Column4 | Column5 | column6 |
|--|-----------------------------------|---------------------|--------------------|---------------------|--------------------|
| antecedents | consequents | antecedent support | consequent support | support | confidence |
| frozenset({'Dev1_M1_Above25'}) | frozenset(['AnomalyFutureEvent']) | 0.16666666666666666 | 0.9766666666666667 | 0.16666666666666666 | 1.0 |
| frozenset(['AnomalyNow']) | frozenset(['AnomalyFutureEvent']) | 0.12333333333333334 | 0.9766666666666667 | 0.12333333333333334 | 1.0 |
| frozenset(['AnomalyNow', 'Dev2_M3_Below10']) | frozenset(['AnomalyFutureEvent']) | 0.03333333333333333 | 0.9766666666666667 | 0.03333333333333333 | 1.0 |
| frozenset(['AnomalyNow', 'Dev3_M2_Above20']) | frozenset(['AnomalyFutureEvent']) | 0.04666666666666667 | 0.9766666666666667 | 0.04666666666666667 | 1.0 |
| frozenset({'Dev1_M1_Above25', 'Dev3_M2_Above20'}) | frozenset(['AnomalyFutureEvent']) | 0.04333333333333335 | 0.9766666666666667 | 0.04333333333333335 | 1.0 |
| frozenset(['AnomalyNow', 'Dev1_M1_Above25']) | frozenset(['AnomalyFutureEvent']) | 0.02666666666666667 | 0.9766666666666667 | 0.02666666666666667 | 1.0 |
| frozenset({'Dev2_M3_Below10', 'Dev3_M2_Above20'}) | frozenset(['AnomalyFutureEvent']) | 0.12666666666666668 | 0.9766666666666667 | 0.12666666666666668 | 1.0 |
| frozenset({'Dev2_M3_Below10', 'Dev1_M1_Above25'}) | frozenset(['AnomalyFutureEvent']) | 0.06666666666666667 | 0.9766666666666667 | 0.06666666666666667 | 1.0 |
| frozenset(['AnomalyNow', 'Dev1_M1_Above25', 'Dev3_M2_Above20']) | frozenset(['AnomalyFutureEvent']) | 0.01333333333333334 | 0.9766666666666667 | 0.01333333333333334 | 1.0 |
| frozenset(['AnomalyNow', 'Dev2_M3_Below10', 'Dev3_M2_Above20']) | frozenset(['AnomalyFutureEvent']) | 0.01 | 0.9766666666666667 | 0.01 | 1.0 |
| frozenset(['AnomalyNow', 'Dev2_M3_Below10', 'Dev1_M1_Above25']) | frozenset(['AnomalyFutureEvent']) | 0.01 | 0.9766666666666667 | 0.01 | 1.0 |
| frozenset({'Dev2_M3_Below10', 'Dev1_M1_Above25', 'Dev3_M2_Above20'}) | frozenset(['AnomalyFutureEvent']) | 0.01 | 0.9766666666666667 | 0.01 | 1.0 |
| frozenset({'Dev3_M2_Above20'}) | frozenset(['AnomalyFutureEvent']) | 0.32 | 0.9766666666666667 | 0.31666666666666665 | 0.9895833333333333 |
| frozenset({'Dev2_M3_Below10'}) | frozenset(['AnomalyFutureEvent']) | 0.35 | 0.9766666666666667 | 0.34333333333333335 | 0.980952380952381 |

Рисунок 4.6 – Перша половина результуючої таблиці

| Column7 | Column8 | Column9 | Column10 | Column11 | Column12 | Column13 | Column14 |
|--------------------|------------------|------------------------|---------------------|----------------------|----------------------|-------------------|-----------------|
| lift | representativity | leverage | conviction | zhangs_metric | jaccard | certainty | kulczynski |
| 1.023890784982935 | 1.0 | 0.0038888888888888886 | inf | 0.027999999999999998 | 0.1706484641638225 | 1.0 | 0.5853242320819 |
| 1.023890784982935 | 1.0 | 0.0028777777777777708 | inf | 0.026615969581748982 | 0.12627986348122866 | 1.0 | 0.5631399317406 |
| 1.023890784982935 | 1.0 | 0.0007777777777777778 | inf | 0.024137931034482828 | 0.034129692832764506 | 1.0 | 0.5170648464163 |
| 1.023890784982935 | 1.0 | 0.0010888888888888892 | inf | 0.024475524475524483 | 0.0477815699658703 | 1.0 | 0.5238907849829 |
| 1.023890784982935 | 1.0 | 0.00101111111111111085 | inf | 0.02439024390243896 | 0.04436860068259386 | 1.0 | 0.5221843003412 |
| 1.023890784982935 | 1.0 | 0.0006222222222222219 | inf | 0.023972602739726012 | 0.0273037542662116 | 1.0 | 0.5136518771331 |
| 1.023890784982935 | 1.0 | 0.0029555555555555585 | inf | 0.02671755725190842 | 0.12969283276450513 | 1.0 | 0.5648464163822 |
| 1.023890784982935 | 1.0 | 0.0015555555555555556 | inf | 0.025000000000000007 | 0.068259385665529 | 1.0 | 0.5341296928327 |
| 1.023890784982935 | 1.0 | 0.00031111111111111096 | inf | 0.023648648648648633 | 0.013651877133105802 | 1.0 | 0.5068259385665 |
| 1.023890784982935 | 1.0 | 0.0002333333333333366 | inf | 0.0235690235690236 | 0.010238907849829351 | 1.0 | 0.5051194539249 |
| 1.023890784982935 | 1.0 | 0.0002333333333333366 | inf | 0.0235690235690236 | 0.010238907849829351 | 1.0 | 0.5051194539249 |
| 1.023890784982935 | 1.0 | 0.0002333333333333366 | inf | 0.0235690235690236 | 0.010238907849829351 | 1.0 | 0.5051194539249 |
| 1.0132252559726962 | 1.0 | 0.004133333333333322 | 2.23999999999999824 | 0.019195046439628435 | 0.32312925170068024 | 0.553571428571425 | 0.6569077076222 |

Рисунок 4.7 – Друга половина результуючої таблиці

4.2 Висновки до четвертого розділу

У четвертому розділі дипломної роботи було проведено експериментальне дослідження, спрямоване на аналіз ефективності системи прогнозування аномалій на основі кластерів та асоціативних правил. На першому етапі було згенеровано тестові дані, що відображають роботу трьох пристроїв з різними параметрами. Штучне додавання аномалій у дані дозволило змоделювати реальні ситуації, коли технологічні процеси зазнають порушень. Цей етап забезпечив необхідну основу для подальшої обробки даних та аналізу.

Дані проходили багаторівневу обробку, що включала кластеризацію за допомогою алгоритму DBSCAN [40-42]. Це дозволило поділити записи на дві основні групи – «Normal» та «Anomaly». Отримані кластери слугували базисом для визначення часових інтервалів до найближчих аномалій, що є критично важливим для прогнозування можливих збоїв у роботі пристроїв.

Додатково були встановлені межі для показників, які дали змогу підготувати дані до формування асоціативних правил. Подальша бінаризація дозволила

консолідувати інформацію у формат, зручний для аналізу за допомогою алгоритму Apriori. На основі оброблених даних було згенеровано асоціативні правила, які демонструють взаємозв'язок між певними умовами роботи обладнання та настанням аномалій.

Результати експериментального дослідження продемонстрували високу ефективність підходу, що включає кластеризацію, прогнозування часових інтервалів до аномалій та генерацію асоціативних правил. Представлені таблиці та графіки відображають чітку послідовність етапів обробки даних та фінальні результати, які можуть бути використані для оптимізації роботи виробничих систем. Таким чином, отримані результати підтверджують можливість інтеграції запропонованої системи у реальні виробничі процеси для підвищення їхньої ефективності та зменшення ризиків.

5 ВПРОВАДЖЕННЯ ІННОВАЦІЙНОЇ СИСТЕМИ НА АВТОМОБІЛЬНОМУ ВИРОБНИЦТВІ

5.1 Особливості інтеграції у виробничі процеси

Впровадження системи автоматизації та моніторингу на автомобільному виробництві є складним і багатогранним процесом, що вимагає ретельного планування та врахування специфіки галузі. Особливості інтеграції таких систем у виробничі процеси полягають у необхідності гармонізації нових технологій із вже існуючими технологічними лініями, стандартами якості та операційними процедурами. Автомобільна промисловість є високотехнологічною галуззю, де точність і надійність є критичними факторами, тому інтеграція повинна бути спрямована на збереження безперервності виробництва та уникнення порушень у роботі основного обладнання [43].

Процес інтеграції передбачає адаптацію системи до специфічних умов експлуатації, які можуть включати високу інтенсивність виробничих циклів, жорсткі вимоги до безпеки та точності, а також необхідність обробки великих обсягів даних.

Складнощі можуть виникати через різноманітність технічних стандартів та специфікацій обладнання, яке використовується на підприємствах автомобільної галузі, тому важливим етапом є створення інтеграційного середовища, що уніфікує обмін даними між різними компонентами системи. Крім того, інтеграція потребує адаптації під конкретні виробничі сценарії, наприклад, процеси складання, фарбування чи тестування, які мають різні вимоги до систем моніторингу. Важливо також враховувати високий рівень автоматизації виробничих ліній, що потребує інтеграції системи без зупинки виробничих процесів, шляхом впровадження модульного підходу. Це дозволяє тестувати окремі компоненти системи в реальних умовах без значних ризиків для загальної продуктивності.

Значна увага приділяється також безпеці та надійності системи, оскільки будь-які збої в роботі можуть призвести до значних фінансових втрат і навіть порушення функціональності автомобільної продукції. Це вимагає впровадження механізмів захисту даних, резервного копіювання, а також стійкості до зовнішніх загроз, таких як кібер-атаки. Для досягнення ефективної інтеграції необхідно забезпечити навчання персоналу, відповідального за обслуговування та експлуатацію системи, а також організацію міждисциплінарної комунікації між інженерним та ІТ-підрозділами компанії.

Інтеграція системи автоматизації у виробничі процеси автомобільної галузі повинна бути спрямована на досягнення довгострокових стратегічних цілей, таких як зменшення витрат, підвищення якості продукції та скорочення часу на виявлення та усунення несправностей. Це є можливим завдяки поєднанню сучасних підходів до управління даними, штучного інтелекту та хмарних обчислень, які забезпечують масштабованість, гнучкість та адаптивність системи в умовах швидких змін ринку.

5.2 Потенційні труднощі та шляхи їх подолання

Потенційні труднощі, що виникають під час впровадження системи автоматизації на автомобільному виробництві, обумовлені складністю виробничих процесів, високим рівнем інтеграції обладнання та вимогами до безпеки. Однією з головних проблем є різноманітність стандартів та протоколів, що використовуються на підприємстві. Зокрема, обладнання різних виробників може підтримувати різні інтерфейси, протоколи передачі даних і формати, що ускладнює їх інтеграцію в єдину систему.

Іншою проблемою є ризик порушення безперервності виробничого процесу. Впровадження нових систем автоматизації може супроводжуватися тимчасовими зупинками ліній або зниженням їх продуктивності. Для мінімізації цих ризиків рекомендується використовувати поетапний підхід до впровадження, починаючи з тестування системи на окремих модулях чи виробничих ділянках. Такий підхід

дозволяє не тільки зменшити вплив на основні операції, але й оцінити ефективність та виявити можливі недоліки до повномасштабного розгортання.

Труднощі також можуть виникати через опір персоналу до змін, особливо якщо система передбачає значні зміни у робочих процесах. Це може бути пов'язано як із недостатнім розумінням переваг автоматизації, так і з побоюваннями щодо зменшення потреби у людській праці. Подолання цієї проблеми потребує ретельної підготовки, яка включає навчання персоналу роботі з новою системою, роз'яснення її переваг, а також забезпечення прозорості щодо змін у функціональних обов'язках.

Впровадження системи автоматизації також вимагає значних інвестицій, що може стати серйозною перешкодою для багатьох підприємств. Особливо це стосується інтеграції сучасних рішень на базі штучного інтелекту та хмарних обчислень, які потребують відповідного технічного забезпечення. Для вирішення цієї проблеми доцільно застосовувати поетапну стратегію, що дозволяє розподілити витрати у часі, а також використовувати модульні рішення, які можна поступово масштабувати. Крім того, варто розглядати можливості фінансування через партнерські програми або державні ініціативи, спрямовані на цифровізацію промисловості.

Ще однією проблемою є управління великими обсягами даних, які генеруються під час роботи системи. Ці дані повинні бути не тільки зібрані, але й ефективно оброблені, збережені та використані для аналітики та прогнозування. Для цього необхідно використовувати сучасні платформи управління даними, які забезпечують високу продуктивність і масштабованість. Важливим аспектом є також забезпечення доступності даних у режимі реального часу, що може вимагати впровадження потужних обчислювальних ресурсів.

Подолання зазначених труднощів можливе завдяки використанню сучасних методологій управління проєктами, таких як Agile або DevOps, що забезпечують гнучкість у процесі впровадження [44]. Крім того, співпраця з досвідченими партнерами та постачальниками технологій може значно знизити ризики та прискорити інтеграцію системи. Завдяки комплексному підходу та належному

плануванню, впровадження систем автоматизації здатне забезпечити значне підвищення продуктивності та конкурентоспроможності автомобільного виробництва.

5.3 Економічний ефект від впровадження системи

Економічний ефект від впровадження системи автоматизації на автомобільному виробництві є багатовимірним і проявляється у різних аспектах діяльності підприємства. Однією з ключових переваг є підвищення продуктивності праці завдяки оптимізації виробничих процесів. Системи автоматизації дозволяють знизити час простоїв обладнання, мінімізувати втрати, пов'язані з людським фактором, та підвищити швидкість виконання операцій [45]. Це, у свою чергу, дає змогу збільшити обсяги виробництва без необхідності значного розширення виробничих потужностей, що сприяє зниженню собівартості продукції.

Ще одним вагомим аспектом є зменшення витрат на обслуговування обладнання. Використання систем моніторингу стану обладнання та прогнозування можливих поломок дозволяє перейти до стратегії профілактичного обслуговування, що значно знижує ймовірність аварійних ситуацій і пов'язаних з ними витрат. Завдяки цьому підприємство може зменшити витрати на запасні частини, скоротити час, необхідний для ремонту, та забезпечити стабільність виробничих процесів.

Важливим економічним ефектом є підвищення якості продукції. Системи автоматизації забезпечують точний контроль за дотриманням технологічних параметрів, що мінімізує кількість дефектів. Завдяки цьому знижується рівень витрат на переробку або утилізацію бракованих виробів, а також підвищується задоволеність клієнтів, що позитивно впливає на репутацію компанії та сприяє зростанню її конкурентоспроможності.

Економічний ефект також проявляється у зростанні гнучкості виробничих процесів. Системи автоматизації дозволяють оперативно адаптувати виробничі потужності до змін попиту, зменшити час на переналаштування обладнання та

запуск нових продуктів. Це сприяє скороченню термінів виконання замовлень і більш ефективному використанню ресурсів.

5.4 Висновки до п'ятого розділу

У п'ятому розділі проаналізовано ключові аспекти впровадження інноваційної системи автоматизації на автомобільному виробництві, включно з особливостями інтеграції у виробничі процеси, потенційними труднощами, шляхами їх подолання та економічним ефектом від реалізації системи. Було встановлено, що успішна інтеграція інноваційних систем вимагає врахування специфіки виробничих процесів, адаптації технологій до існуючої інфраструктури та забезпечення належної кваліфікації персоналу. Зокрема, виділено важливість поетапного впровадження з акцентом на мінімізацію ризиків для безперервності виробництва.

Аналіз потенційних труднощів показав, що основні проблеми пов'язані з високими початковими інвестиціями, необхідністю технічного обслуговування системи, можливим опором змін з боку працівників та інтеграцією різномірних компонентів [46]. Запропоновано шляхи подолання цих викликів, зокрема шляхом впровадження навчальних програм, використання модульних рішень для поступового оновлення виробництва та залучення зовнішніх експертів для супроводу впровадження.

Розглянутий економічний ефект від впровадження системи свідчить про значний потенціал для підвищення ефективності виробництва. До основних переваг належать зменшення витрат на обслуговування обладнання, підвищення енергоефективності, скорочення часу простоїв, покращення якості продукції та зниження операційних витрат. Ці аспекти створюють умови для стійкого розвитку підприємства та його конкурентоспроможності на ринку.

Загалом, впровадження системи автоматизації на автомобільному виробництві є стратегічно важливим кроком, що сприяє не лише оперативному підвищенню ефективності, але й формуванню довгострокових переваг

6 БЕЗПЕКА ПРАЦІ ТА ЕКОЛОГІЧНІ АСПЕКТИ

6.1 Аналіз потенційних ризиків при використанні інноваційної системи

Аналіз потенційних ризиків при використанні системи прогнозування аномалій на основі кластерів та асоціативних правил є важливим етапом впровадження таких інновацій у виробничі процеси автомобільної галузі. Попри значний потенціал для підвищення ефективності та надійності обладнання, подібні системи супроводжуються низкою викликів, які можуть негативно вплинути на їхню ефективність та безпеку [47].

Один із ключових ризиків пов'язаний із якістю даних, які використовуються для навчання та роботи системи. Недостатня кількість даних, їхня нерепрезентативність або наявність шуму в записах можуть призвести до формування неточних моделей прогнозування, що знижує їхню ефективність і може спричинити хибнопозитивні або хибнонегативні результати. Це, своєю чергою, здатне викликати додаткове навантаження на операторів або призвести до пропуску критичних аномалій.

Ще одним ризиком є складність інтерпретації результатів. Алгоритми кластеризації та асоціативних правил, особливо в умовах великої кількості параметрів, можуть генерувати надмірно складні моделі, які важко інтерпретувати для прийняття управлінських рішень. Це може створити бар'єр для ефективного впровадження системи на рівні операторів та менеджерів, які не володіють необхідними технічними навичками.

Крім того, варто враховувати ризик недостатньої адаптації системи до змін у виробничих процесах. Динамічне середовище автомобільного виробництва може вимагати частого оновлення моделей, оскільки навіть незначні зміни в параметрах обладнання можуть вплинути на точність прогнозів. Якщо система не забезпечена механізмами адаптації або автоматичного перенавчання, її ефективність може значно знижуватися.

Питання кібербезпеки також є критичним. Оскільки система працює з великими обсягами даних, які можуть включати конфіденційну інформацію про технологічні процеси, існує ризик витоку даних або несанкціонованого втручання, що може призвести до маніпуляцій у прогнозах або навіть до зупинки виробництва.

Ще одним аспектом є технічні обмеження інфраструктури. Наприклад, недостатня обчислювальна потужність обладнання або низька пропускну здатність мереж можуть уповільнювати роботу системи, викликаючи затримки в обробці даних і формуванні прогнозів. Це може бути критично важливим у виробничих середовищах, де необхідна швидка реакція на відхилення.

Для мінімізації зазначених ризиків необхідно забезпечити високоякісний збір і підготовку даних, використовувати методи очищення та попередньої обробки. Регулярне перенавчання моделей із використанням актуальних даних дозволить системі адаптуватися до змін у виробництві. Варто також впроваджувати навчальні програми для персоналу, щоб підвищити розуміння принципів роботи системи та підготувати його до використання складних алгоритмів. Для забезпечення кібербезпеки необхідно впроваджувати сучасні методи захисту даних, включаючи шифрування та багаторівневу аутентифікацію. Технічна інфраструктура має бути оптимізована для задоволення вимог продуктивності та масштабованості системи.

Таким чином, врахування потенційних ризиків на етапі впровадження систем прогнозування аномалій є важливою передумовою для забезпечення їхньої ефективної роботи та інтеграції в існуючі технологічні процеси.

6.2 Організація безпечної експлуатації обладнання та ПЗ

Організація безпечної експлуатації обладнання та програмного забезпечення є ключовим аспектом впровадження інноваційної системи на автомобільному виробництві. Забезпечення безпеки передбачає системний підхід, який охоплює технічні, організаційні та нормативно-правові аспекти. Цей процес має бути спрямований на мінімізацію ризиків для здоров'я персоналу, запобігання аваріям та дотримання екологічних стандартів.

Технічна безпека передбачає проведення регулярного технічного обслуговування обладнання, моніторинг його стану за допомогою вбудованих діагностичних систем і оперативне усунення несправностей. Особлива увага повинна приділятися системам аварійного відключення, які мають бути готовими до миттєвої реакції у разі виникнення надзвичайної ситуації. Крім того, програмне забезпечення повинно бути захищеним від помилок і збоїв через систематичні оновлення, тестування та використання резервних копій даних.

Організаційні заходи з безпеки включають розробку та впровадження чітких інструкцій з експлуатації обладнання та програмного забезпечення [48]. Усі працівники повинні пройти навчання та атестацію, щоб забезпечити їхню здатність правильно та безпечно користуватися новими технологіями. Регулярне проведення тренінгів з охорони праці, включаючи симуляції аварійних ситуацій, дозволяє підвищити рівень підготовленості персоналу до роботи в умовах можливих загроз.

Для дотримання екологічних вимог необхідно впроваджувати технології, які мінімізують споживання енергії та утворення відходів. Це може включати використання енергоефективних компонентів, забезпечення належної утилізації відпрацьованих матеріалів і застосування вторинної переробки. Також важливим є забезпечення моніторингу впливу на навколишнє середовище за допомогою спеціалізованого обладнання та програмних рішень.

Загалом організація безпечної експлуатації обладнання та програмного забезпечення вимагає інтегрованого підходу, що базується на сучасних технологіях, систематичному аналізі ризиків і постійному підвищенні кваліфікації персоналу. Такий підхід дозволяє досягти високого рівня безпеки, знизити ймовірність технічних збоїв і сприяти довготривалій екологічній стабільності виробництва.

6.3 Екологічні переваги та зменшення енергоспоживання

Впровадження системи прогнозування аномалій на основі кластерів та асоціативних правил у автомобільному виробництві відкриває значні екологічні

переваги та сприяє зменшенню енергоспоживання. Такий підхід дозволяє використовувати аналітику великих даних для точного моніторингу технологічних процесів, забезпечуючи оптимізацію споживання енергоресурсів, мінімізацію втрат і зниження екологічного навантаження.

Прогнозування аномалій дає змогу своєчасно виявляти відхилення в роботі обладнання, що дозволяє уникати нераціонального споживання енергії через роботу несправних чи малоефективних систем. Завдяки кластеризації даних про стан обладнання та аналізу асоціативних правил, система ідентифікує потенційні поломки ще до їхнього виникнення. Це зменшує кількість аварійних зупинок і потребу у повторному запуску виробничих ліній, які зазвичай супроводжуються високими енергетичними витратами.

Крім того, такі системи сприяють переходу до предиктивного обслуговування, яке є екологічно доцільнішим порівняно з традиційним реактивним підходом [49]. Прогнозування аномалій дозволяє планувати ремонтні роботи в моменти найменшого навантаження, що допомагає знизити споживання енергії під час простоїв обладнання. Також це запобігає роботі пристроїв у режимах, які можуть бути енергетично неефективними через поступове зношування.

Система прогнозування на основі асоціативних правил допомагає ідентифікувати взаємозалежності між різними параметрами роботи обладнання, що дозволяє оптимізувати режими роботи з урахуванням енергетичних потреб. Наприклад, вона може визначити умови, за яких певні технологічні операції споживають надмірну кількість енергії, і рекомендувати зміни в налаштуваннях для досягнення енергоефективності.

Впровадження такої системи також сприяє зниженню викидів парникових газів. Ефективне управління енергоресурсами завдяки точному прогнозуванню зменшує обсяги спалювання викопного палива, що використовується для живлення виробничих процесів. Окрім того, оптимізована робота обладнання знижує навантаження на енергетичні мережі, що є особливо важливим у контексті інтеграції відновлюваних джерел енергії у виробничі процеси.

Системи прогнозування аномалій також підтримують принципи циркулярної економіки. Завдяки моніторингу стану матеріалів і компонентів, вони допомагають ефективніше управляти залишками, зменшуючи кількість відходів і сприяючи їх повторному використанню. Це зменшує потребу у видобутку нових ресурсів, що позитивно впливає на екосистеми.

Таким чином, впровадження систем прогнозування аномалій на основі кластерів і асоціативних правил є не лише технічно прогресивним, а й екологічно доцільним рішенням. Воно забезпечує оптимізацію енергоспоживання, зниження екологічного сліду виробництва та сприяє сталому розвитку автомобільної галузі.

6.4 Висновки до шостого розділу

Автоматизована система прогнозування поломок відіграє ключову роль у забезпеченні безпеки праці, покращенні екологічної ситуації та створенні комфортніших умов роботи на автомобільному виробництві. Її впровадження дозволяє мінімізувати ризики для персоналу завдяки завчасному виявленню потенційних несправностей і попередженню аварійних ситуацій. Це сприяє формуванню культури безпечної праці, де пріоритетом є здоров'я працівників і створення безпечних умов для виконання робочих обов'язків.

Система також має суттєвий вплив на зниження екологічного навантаження виробничих процесів. Раціональне використання ресурсів, зокрема енергії та сировини, забезпечується через оптимізацію роботи обладнання та зменшення його зносу. Зменшення кількості аварійних зупинок і поломок обладнання знижує обсяги промислових відходів, сприяючи більш сталому виробництву [50-55]. Крім того, зниження енергоспоживання обладнання позитивно впливає на загальну екологічну ситуацію, сприяючи зменшенню викидів парникових газів.

Одним із найважливіших аспектів впровадження системи є її здатність підтримувати сталий розвиток підприємства. Використання сучасних технологій, таких як алгоритми DBSCAN і Apriori, дозволяє не лише підвищити ефективність роботи обладнання, а й забезпечити його безпечну експлуатацію. Це сприяє

довгостроковому збереженню технічного стану устаткування, що позитивно впливає на економічну стабільність підприємства.

Загалом, автоматизована система прогнозування поломок є важливим інструментом у досягненні балансу між продуктивністю виробництва, безпекою праці та захистом навколишнього середовища. Її впровадження створює передумови для модернізації виробничих процесів, забезпечуючи більш екологічне та соціально відповідальне функціонування підприємства. Завдяки цій системі виробництво стає не лише ефективнішим, але й безпечнішим для працівників і дружнім до навколишнього середовища.

ВИСНОВКИ

У ході виконання кваліфікаційної роботи було розроблено систему прогнозування поломок на автоматизованому автомобільному виробництві, яка базується на інтеграції алгоритмів асоціативного аналізу та кластеризації. Основною метою роботи було підвищення ефективності виробничих процесів через раннє виявлення потенційних проблем та аномалій, що дозволяє мінімізувати ризики для підприємства та його працівників. Запропонована система використовує алгоритм DBSCAN для кластеризації даних та ідентифікації аномалій, а також алгоритм Apriori для формування асоціативних правил, що забезпечують прогнозування майбутніх подій. Експериментальні дослідження на синтетичних даних підтвердили здатність системи ідентифікувати закономірності та прогнозувати поломки з високою точністю.

Використання часових вікон для аналізу даних дозволило врахувати короткострокові та довгострокові зміни в роботі обладнання, що сприяло підвищенню точності прогнозування. Гнучкість налаштувань системи, таких як параметри алгоритмів DBSCAN і Apriori, забезпечує адаптацію до різних умов роботи виробничого обладнання. Система показала високу ефективність в умовах різнорідних і нерівномірних даних із сенсорів, що підтверджує її універсальність та можливість впровадження на виробництвах різного масштабу.

Впровадження запропонованої системи на автомобільному виробництві сприяє не лише підвищенню надійності виробничих процесів, але й створює умови для сталого розвитку підприємства. Економічний ефект від застосування системи полягає у зниженні витрат на ремонт обладнання та мінімізації втрат від простоїв, що дозволяє підвищити загальну продуктивність. Крім того, система сприяє забезпеченню безпеки праці, оскільки дозволяє своєчасно виявляти небезпечні ситуації та попереджати їх. Зменшення кількості аварійних ситуацій позитивно впливає на здоров'я персоналу та умови праці загалом. Екологічний ефект системи

досягається за рахунок оптимізації ресурсів та зменшення енергоспоживання, що відповідає сучасним принципам сталого розвитку.

Наукова новизна роботи полягає в запропонованій методиці інтеграції алгоритмів кластеризації та асоціативного аналізу для прогнозування поломок на виробничих системах, а також у використанні часових вікон для підвищення точності аналізу. Практична цінність роботи визначається можливістю впровадження розробленої системи на різних підприємствах для покращення їхньої ефективності та конкурентоспроможності. Подальші дослідження можуть бути спрямовані на використання методів машинного навчання для підвищення точності прогнозування, а також на розширення системи для роботи з великими потоками даних у реальному часі. Отримані результати можуть бути основою для створення високотехнологічних систем моніторингу стану обладнання, що забезпечать стабільну роботу підприємств у довгостроковій перспективі.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Методичні вказівки з підготовки та захисту кваліфікаційної роботи здобувачами другого (магістерського) рівня вищої освіти спеціальності 174 Автоматизація, комп'ютерно-інтегровані технології та робототехніка, освітньо-професійних програм: «Комп'ютерно-інтегровані технологічні процеси і виробництва», «Комп'ютеризовані та робототехнічні системи» / Упоряд. І. Ш. Невлюдов, Р. В. Артюх, В. В. Безкоровайний, Н. П. Демська, В. В. Євсєєв, О. І. Филипенко, О. М. Цимбал. Харків: ХНУРЕ, 2024. 57 с.
2. ДСТУ 3008-15. Інформація та документація. Звіти у сфері науки та техніки. Структура та правила оформлювання. / Нац. стандарт України. – Вид. офіц. – [Чинний від 2015-06-22]. – Київ: Держстандарт України, 2017. – 26 с.
3. Положення про академічну доброчесність [Електронний ресурс]: наказ ХНУРЕ від 02 лютого 2021 р. № 50. – Режим доступу: https://nure.ua/wpcontent/uploads/Main_Docs_NURE/polozhennja-pro-akademi-chnu-dobrochesnist.pdf.
4. Основи наукових досліджень : підручник / І. Ш. Невлюдов, Ю. М. Олександров, А. О. Андрусевич, О. О. Чала ; М-во освіти і науки України, Харків. нац. ун-т радіоелектроніки. – Prague : OKTAN PRINT, 2024. – 468 с.
5. Li L., et al. Evaluating the impact of big data analytics usage on the decision-making quality of organizations / L. Li, et al. // Technological Forecasting and Social Change. – 2022. – Vol. 175. – Article 121355.
6. Duan L., Xu L. D. Data analytics in Industry 4.0: A survey / L. Duan, L. D. Xu // Information Systems Frontiers. – 2021. – P. 1–17.
7. Ситніков Д. Е., Ситнікова П. Е., Тітов С. В., Тітова О. В. Фільтрація результуючого набору асоціативних правил з точки зору оцінки цікавості // Системи обробки інформації. – 2021. – № 1 (164). – С. 83–88.

8. Sitnikov D., Sytnikova P., Kovalenko A. Methods of Eliminating Features from Linguistic Equations // CEUR Workshop Proceedings. – 2021. – Vol. 2870. – P. 877–889.
9. Schubert E., et al. DBSCAN revisited, revisited: why and how you should (still) use DBSCAN / E. Schubert, et al. // ACM Transactions on Database Systems (TODS). – 2017. – Vol. 42, № 3. – P. 1–21.
10. Khan K., et al. DBSCAN: Past, present and future / K. Khan, et al. // The Fifth International Conference on the Applications of Digital Information and Web Technologies (ICADIWT 2014). – IEEE, 2014.
11. Deng D. DBSCAN clustering algorithm based on density / D. Deng // 2020 7th International Forum on Electrical Engineering and Automation (IFEEA). – IEEE, 2020.
12. Ситніков Д. Е., Ситнікова П. Е., Тітов С. В., Тітова О. В. Визначення параметрів узагальнених асоціативних правил методом декомпозиції // Системи обробки інформації. – 2019. – С. 58–63.
13. Agrawal R., Imielinski T., Swami A. Mining association rules between sets of items in large databases / R. Agrawal, T. Imielinski, A. Swami // Proc. of the ACM SIGMOD Conference. – Washington DC, USA, May 1993. – P. 207–216.
14. Srikant R., Agrawal R. Mining generalized association rules / R. Srikant, R. Agrawal // Proc. of the 21st VLDB Conference. – Zurich, Switzerland, September 1995. – P. 407–419.
15. Wang J., et al. Big data analytics for intelligent manufacturing systems: A review / J. Wang, et al. // Journal of Manufacturing Systems. – 2022. – Vol. 62. – P. 738–752.
16. Mölder F., et al. Sustainable data analysis with Snakemake / F. Mölder, et al. // F1000Research. – 2021. – Vol. 10.
17. Dries R., et al. Advances in spatial transcriptomic data analysis / R. Dries, et al. // Genome Research. – 2021. – Vol. 31, № 10. – P. 1706–1718.
18. Nevliudov I & et al.. Method of Algorithms for Cyber-Physical Production Systems Functioning Synthesis // International Journal of Emerging Trends in Engineering Research. – 2020. – P.7465-7473

19. Sharifani K., Amini M. Machine learning and deep learning: A review of methods and applications / K. Sharifani, M. Amini // World Information Technology and Engineering Journal. – 2023. – Vol. 10, № 07. – P. 3897–3904.
20. Zhou Z.-H. Machine Learning / Z.-H. Zhou. – Springer Nature, 2021.
21. Li W., et al. International conference on machine learning / W. Li, et al. // Transactions on Machine Learning Research. – 2023.
22. Janiesch C., Zschech P., Heinrich K. Machine learning and deep learning / C. Janiesch, P. Zschech, K. Heinrich // Electronic Markets. – 2021. – Vol. 31, № 3. – P. 685–695.
23. Виробничі процеси та обладнання об'єктів автоматизації : Підручник для студентів вищих навчальних закладів / І. Ш. Невлюдов. Кривий Ріг: Криворізький коледж НАУ, 2017 р. – 444 с.
24. Невлюдов І. Ш. Виробничі процеси та обладнання об'єктів автоматизації: збірник задач: навч. посіб. / І. Ш. Невлюдов, А. О. Андрусевич, Г. В. Пономарьова, А. О. Функендорф. – Кривий Ріг: Криворізький коледж НАУ, 2017. – 332 с.
25. Невлюдов І. Ш. Техніко-економічне обґрунтування інженерних рішень в інтелектуальному виробництві: підручник / І. Ш. Невлюдов; Кривий Ріг : видавець Чернявський Д. О., 2024. – 388 с.
26. Невлюдов І. Ш. Комп'ютерно-інтегровані технології виробництва технічних засобів автоматизації. Частина 1: підручник / І. Ш. Невлюдов. – Харків: ФОП Панов А. М., 2021. – 604 с.
27. Невлюдов І. Ш. Теорія автоматичного управління (збірник задач): навч. посіб. для студентів спеціальності 151 «Автоматизація та комп'ютерно-інтегровані технології» / І. Ш. Невлюдов, О. В. Токарєва. – Харків: ХНУРЕ, 2020. – 240 с. – ISBN 978-617-7859-57-3.
28. Теорія автоматичного управління (збірник задач): навч. посіб. для студентів спеціальності 151 "Автоматизація та комп'ютерно-інтегровані технології" / І. Ш. Невлюдов, О. В. Токарєва ; Харків. нац. ун-т радіоелектроніки. – Харків : Панов А. М., 2020. – 240 с.
29. Python W. Python / W. Python // Python Releases for Windows. – 2021.

30. Aziz Z. A., et al. Python parallel processing and multiprocessing: A review / Z. A. Aziz, et al. // Academic Journal of Nawroz University. – 2021. – Vol. 10, № 3. – P. 345–354.
31. McKinney W. Python for Data Analysis / W. McKinney. – Sebastopol: O'Reilly Media, Inc., 2022.
32. Zheng Y., et al. Causal-learn: Causal discovery in Python / Y. Zheng, et al. // Journal of Machine Learning Research. – 2024. – Vol. 25, № 60. – P. 1–8.
33. Amir A., Feldman R., Kashi R. A new and versatile method for association generation / A. Amir, R. Feldman, R. Kashi // Information Systems. – 1997. – Vol. 22, № 6/7. – P. 333–347.
34. Sitnikov D., Titova O., Minukhin S., Kovalenko A., Titov S. Informativity of Association Rules from the Viewpoint of Information Theory / D. Sitnikov, O. Titova, S. Minukhin, A. Kovalenko, S. Titov // International Scientific-Practical Conference. – 2018. – P. 595–598.
35. Gan J., Tao Y. DBSCAN revisited: Mis-claim, un-fixability, and approximation / J. Gan, Y. Tao // Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data. – 2015.
36. Gholizadeh N., Saadatfar H., Hanafi N. K-DBSCAN: An improved DBSCAN algorithm for big data / N. Gholizadeh, H. Saadatfar, N. Hanafi // The Journal of Supercomputing. – 2021. – Vol. 77, № 6. – P. 6214–6235.
37. Selvan C., Balasundaram S. R. Data analysis in context-based statistical modeling in predictive analytics / C. Selvan, S. R. Balasundaram // Handbook of Research on Engineering, Business, and Healthcare Applications of Data Science and Analytics. – IGI Global, 2021. – P. 96–114.
38. Siregar A. H., Lydia M. S., Wage S. Association Rule Analysis using CT-Pro and Hash-based Algorithm in Violence Case of Children / A. H. Siregar, M. S. Lydia, S. Wage // Cesit. – 2021. – No. Cesit. – P. 565–573.
39. Golalipour K., et al. From clustering to clustering ensemble selection: A review / K. Golalipour, et al. // Engineering Applications of Artificial Intelligence. – 2021. – Vol. 104. – Article 104388.

40. Ren Y., et al. Deep clustering: A comprehensive survey / Y. Ren, et al. // *IEEE Transactions on Neural Networks and Learning Systems*. – 2024.
41. Hanafi N., Saadatfar H. A fast DBSCAN algorithm for big data based on efficient density calculation / N. Hanafi, H. Saadatfar // *Expert Systems with Applications*. – 2022. – Vol. 203. – Article 117501.
42. Ran X., et al. Comprehensive survey on hierarchical clustering algorithms and the recent developments / X. Ran, et al. // *Artificial Intelligence Review*. – 2023. – Vol. 56, № 8. – P. 8219–8264.
43. Бей Н. О. Історичні особливості розвитку науково-технологічних процесів виробництва вантажних автомобілів на Кременчуцькому автомобільному заводі у другій половині ХХ – на початку ХХІ століть / Н. О. Бей // *Історія науки і біографістика*. – 2017.
44. Русіло П. О., Костюк В. В., Афонін В. М. Вплив на довкілля автомобільного транспорту на всіх стадіях його життєвого циклу / П. О. Русіло, В. В. Костюк, В. М. Афонін // *Науковий вісник НЛТУ України*. – 2008. – Т. 18, № 3. – С. 85–89.
45. Moh'd S., et al. Agile human resource management: A systematic mapping study / S. Moh'd, et al. // *German Journal of Human Resource Management*. – 2024. – Vol. 38, № 4. – P. 345–374.
46. Wang H., Smys S. Big data analysis and perturbation using data mining algorithm / H. Wang, S. Smys // *Journal of Soft Computing Paradigm (JSCP)*. – 2021. – Vol. 3, № 01. – P. 19–28.
47. Крайнюк О. В., Буц Ю. В., Барбашин В. В. SWOT-Аналіз впровадження цифрових технологій для забезпечення безпеки праці / О. В. Крайнюк, Ю. В. Буц, В. В. Барбашин // *Комунальне господарство міст*. – 2021. – № 163. – С. 234–238.
48. Жуковська В. М. Безпека праці та здоров'я персоналу в умовах війни: розробка HR проекту / В. М. Жуковська // *Бізнес Інформ*. – 2022. – № 10. – С. 108–113.

49. Функціонування транспортної системи автотранспортного підприємства / Т. В. Волобуєва, С. М. Мастепан, М. А. Мастепан // Вісник машинобудування та транспорту. – 2024. – Т. 19, № 1. – С. 21–28.

50. Легеза Д. Г. Розробка заходів щодо підвищення екологічної безпеки автотранспортного підприємства середньої потужності / Д. Г. Легеза. – 2022.

51. Бутенко Д. О. Ризики для здоров'я у ливарному виробництві / Д. О. Бутенко // Фізичне виховання, безпека життєдіяльності і сучасні технології виробництва: збірник. – 2024. – С. 293.

52. Даценко В. В. Оцінка екологічної безпеки відходів гальванічного виробництва / В. В. Даценко // Інформаційні технології: наука, техніка, технологія, освіта, здоров'я = Information technologies: science, engineering, technology, education, health : тези доп. 29-ї міжнар. наук.-практ. конф. MicroCAD–2021, [18-20 травня 2021 р.] : у 5 ч. Ч. 3 / ред. Є. І. Сокол. – Харків : Планета-Прінт, 2021. – С. 276.

53. Сакалова Г. В., Крикливий Р. Д., Трач І. А. Використання глинистих сорбційних матеріалів в технологіях виробництва каучуків / Г. В. Сакалова, Р. Д. Крикливий, І. А. Трач // Вісник Вінницького політехнічного інституту. – 2022. – № 2. – С. 23–27.

54. Городецький І., Мазур І., Магац М. Актуальність удосконалення управління безпекою праці для розвитку виробництва / І. Городецький, І. Мазур, М. Магац // Актуальні проблеми сучасного бізнесу: обліково-фінансовий та управлінський аспекти : матеріали VI Міжнародної науково-практичної інтернет-конференції, 27–28 березня 2024 р. – Львів : ЛНУП, 2024. – С. 85–87.

55. Розієв Я. А. Кваліфікаційна робота за освітнім ступенем «Бакалавр» освітньо-професійної програми «Екологія, охорона навколишнього середовища та збалансоване природокористування» на тему «Підвищення ефективності заходів по забезпеченню екологічної безпеки на машинобудівних підприємствах» / Я. А. Розієв. – Київ, 2023. – 55 с.